


UNIVERSIDADE FEDERAL DO PARANÁ

PAULO SERGIO DA CONCEIÇÃO MOREIRA

**MINERAÇÃO DE DADOS APLICADA À CLASSIFICAÇÃO AUTOMÁTICA DE  
GÊNEROS MUSICAIS**



CURITIBA  
2017

PAULO SERGIO DA CONCEIÇÃO MOREIRA

**MINERAÇÃO DE DADOS APLICADA À CLASSIFICAÇÃO AUTOMÁTICA DE  
GÊNEROS MUSICAIS**

Trabalho de Conclusão de Curso apresentado como requisito parcial à obtenção de grau de Bacharel no Curso de Gestão da Informação, Departamento de Ciência e Gestão da Informação, do Setor de Ciências Sociais Aplicadas, da Universidade Federal do Paraná.

Orientadora: Prof.<sup>a</sup> Dr.<sup>a</sup> Denise Fukumi Tsunoda.

CURITIBA  
2017

## RESUMO

Estudo de natureza quantitativa que objetiva classificar gêneros musicais automaticamente por meio da aplicação de algoritmos de Mineração de Dados, considerando a análise de características extraídas do sinal de áudio. Identifica-se na Last.fm as 150 músicas mais populares de sete gêneros musicais (rock, jazz, pop, música clássica, MPB, heavy metal e samba). Mediante a extração de descritores relacionados ao domínio do tempo e da frequência destas músicas, constrói-se duas bases de dados: a primeira, considerando a duração original dos arquivos; a segunda, considerando a duração de 30 segundos para cada registro. Aplica-se os algoritmos *Random Forest*; *Bayes Net*; *AdaBoost*; *Bagging*; SVM e KNN para a tarefa de classificação. Obtém-se como melhor resultado 66,53% de acerto com a combinação dos algoritmos *Bagging* e *Bayes Net*. Constata-se que a classificação de gêneros musicais se apresenta como um “problema interessante” para estudos que envolvem técnicas de Aprendizagem de Máquina, uma vez que existem gêneros formados a partir da combinação de elementos de outros gêneros, o que dificulta a diferenciação destes. Estimula-se a continuidade de estudos semelhantes aplicando algoritmos baseados em Redes Neurais e Algoritmos Genéticos.

Palavras-chave: Classificação Automática. Gêneros Musicais. Mineração de Dados.

## **ABSTRACT**

A quantitative study that aims to automatically classify musical genres through the application of Data Mining algorithms, considering the analysis of features extracted from the audio signal. The 150 most popular songs from seven musical genres (rock, jazz, pop, classical music, MPB, heavy metal and samba) were identified in Last.fm. By extracting descriptors related to the domain of time and frequency of these songs, two databases were constructed: the first, considering the original duration of the files; the next, considering the duration of 30 seconds for each record. For the classification task, the following algorithms were used: Random Forest, Bayes Net, AdaBoost, Bagging, SVM and KNN. The best result was a 66.53% accuracy with the combination of the Bagging and Bayes Net algorithms. The classification of musical genres is understood as an "interesting problem" for studies that involve Machine Learning techniques, since there are genres built from the combination of elements of other genres, what makes it difficult to differentiate them. The continuity of similar studies by applying algorithms based on Neural Networks and Genetic Algorithms is stimulated.

**Keywords:** Automatic Classification. Musical genres. Data Mining.

## RÉSUMÉ

Une étude quantitative qui vise à classer automatiquement les genres musicaux par l'application d'algorithmes d'Exploration de Données, considérant l'analyse des caractéristiques extraites du signal audio. Les 150 chansons les plus populaires de sept genres musicaux (rock, jazz, pop, musique classique, MPB, heavy metal et samba) ont été identifiées sur la radio Last.fm. En extrayant des descripteurs liés au domaine de temps et de fréquence de ces chansons, deux bases de données ont été construites: la première, compte tenu de la durée originale des fichiers; la seconde, compte tenu de la durée de 30s pour chaque enregistrement. Des algorithmes de *Random Forest*, *Bayes Net*, *AdaBoost*, *Bagging*, SVM et KNN ont été appliqués pour le travail de classification. Le meilleur résultat a été obtenu, avec une précision de 66,53%, avec la combinaison des algorithmes *Bagging* et *Bayes Net*. La classification des genres musicaux est présentée comme un "problème intéressant" pour les travaux qui impliquent des techniques d'Apprentissage de Machine, depuis qu'il y a des genres formés à partir de la combinaison d'éléments d'autres genres, ce qui rend difficile leur différenciation. La continuité des études similaires est encouragée appliquant des algorithmes basés sur les Réseaux Neuronaux et les Algorithmes Génétiques.

Mots-clés: Classification Automatique. Genres Musicaux. Exploration de Données.

## LISTA DE FIGURAS

FIGURA 1- AS 10 PRINCIPAIS ÁREAS DE PESQUISA EM DATA MINING.....	17
FIGURA 2- AS 10 PRINCIPAIS ÁREAS DE PESQUISA EM DATA MINING E MUSIC .....	18
FIGURA 3- AS 10 PRINCIPAIS ÁREAS DE PESQUISA EM MUSIC GENRE CLASSIFICATION.....	18
FIGURA 4- AS PRINCIPAIS ÁREAS DE PESQUISA EM DATA MINING E MUSIC CLASSIFICATION.....	19
FIGURA 5- AS PRINCIPAIS ÁREAS DE PESQUISA EM DATA MINING E MUSIC GENRE CLASSIFICATION .....	19
FIGURA 6- PROCESSO SIMPLIFICADO DE RECUPERAÇÃO DE INFORMAÇÃO	25
FIGURA 7- TAXONOMIA DOS MODELOS DE RI.....	26
FIGURA 8- MODELO DO PROCESSO DE MUSIC INFORMATION RETRIEVAL ...	28
FIGURA 9- TIME-FEATURES EXTRACTION.....	34
FIGURA 10- VISÃO GERAL DO SISTEMA DE CLASSIFICAÇÃO PROPOSTO POR COSTA, VALLE E KOERICH (2004).....	35
FIGURA 11- DEMONSTRAÇÃO DO PROCESSO DE EXTRAÇÃO DE CARACTERÍSTICAS.....	36
FIGURA 12- EXTRAÇÃO DE CARACTERÍSTICAS .....	37
FIGURA 13- ETAPAS DO KDD.....	38
FIGURA 14- PROCESSO DE KDD COM CINCO ETAPAS .....	39
FIGURA 15- MODELO BASEADO EM CONHECIMENTO. ....	44
FIGURA 16- MODELO BASEADO EM ÁRVORES.....	44
FIGURA 17- MODELO CONEXIONISTA.....	45
FIGURA 18- MODELO BASEADO EM DISTÂNCIA.....	45
FIGURA 19- MODELO BASEADO EM FUNÇÃO.....	46
FIGURA 20- MODELO PROBABILÍSTICO.....	46
FIGURA 21- SÍNTESE DA CARACTERIZAÇÃO DA PESQUISA.....	55
FIGURA 22- PROCEDIMENTOS METODOLÓGICOS: KDD.....	55
FIGURA 23- CONVERSOR ONLINE .....	62
FIGURA 24- RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL (RANDOM FOREST).....	70

FIGURA 25- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO ORIGINAL (RANDOM FOREST).....	70
FIGURA 26- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO ORIGINAL (BAYES NET).....	71
FIGURA 27- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO ORIGINAL (KNN) .....	72
FIGURA 28- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO ORIGINAL (SVM) .....	73
FIGURA 29- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO ORIGINAL (BAGGING) .....	75
FIGURA 30- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO ORIGINAL (BOOSTING).....	76
Figura 31- RESULTADOS PARA A BASE COM DURAÇÃO DE 30 S (RANDOM FOREST).....	77
FIGURA 32- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO DE 30 S (RANDOM FOREST).....	78
FIGURA 33- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO DE 30 S (BAYES NET).....	79
FIGURA 34- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO DE 30 S (KNN) .....	80
FIGURA 35- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO DE 30 S (SVM) .....	81
FIGURA 36- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO DE 30 S (BAGGING) .....	82
FIGURA 37- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO DE 30 S (BOOSTING).....	84

## LISTA DE QUADROS

QUADRO 1- RESULTADOS OBTIDOS NA BASE WEB OF SCIENCE.....	17
QUADRO 2- RESULTADOS OBTIDOS NA BASE IEEE XPLORE .....	20
QUADRO 3- QUADRO DE REFERÊNCIAS .....	24
QUADRO 4- PRINCIPAIS TAREFAS DOS SISTEMAS DE MIR .....	29
QUADRO 5- RELAÇÃO ENTRE PROPRIEDADES DE TEMPO DE UM SINAL E A REPRESENTAÇÃO DE FOURIER APROPRIADA.....	32
QUADRO 6- APLICAÇÕES DAS TAREFAS DE MINERAÇÃO DE DADOS NA MÚSICA .....	50
QUADRO 7- TAREFAS E TÉCNICAS PARA A CLASSIFICAÇÃO DE MÚSICAS....	51
QUADRO 8- FERRAMENTAS PARA EXTRAÇÃO DE CARACTERÍSTICAS DO SINAL DO ÁUDIO. ....	56
QUADRO 9- FERRAMENTAS PARA MINERAÇÃO DE DADOS. ....	60
QUADRO 10- RELAÇÃO DOS DESCRITORES EXTRAÍDOS DA BASE COM DURAÇÃO ORIGINAL. ....	63
QUADRO 11- RELAÇÃO DOS DESCRITORES EXTRAÍDOS DA BASE COM DURAÇÃO DE 30 S. ....	64



## LISTA DE ABREVIATURAS

ARRF - *Attribute-Relation File Format*  
CART - *Classification and Regression Trees*  
DFT – Transformada Discreta de Fourier  
DTFS - Série de Fourier de Tempo Discreto  
DFTT- Transformada de Fourier de Tempo Discreto  
DWCHs - *Daubechies Wavelet Coefficient Histograms*  
DWPT - *Discrete Wavelet Packet Transform*  
FFT - *Fast Fourier Transform*  
FS – Série de Fourier  
FT - Transformada de Fourier  
HM – *Heavy Metal*  
ICC – Instâncias Classificadas Corretamente  
IOIHC - *Inset-Onset*  
KDD - *Knowledge Discovery in Database*  
KNN - *K-Nearest Neighbour*  
LDA - *Linear Discriminant Analysis*  
LMD - *Latin Music Database*  
LPC - *Linear Predictive Coding*  
MC – Música Clássica  
MFCC - *Mel-Frequency Cepstral Coefficients*  
MIDI - *Musical Instrument Digital Interface*  
MIR - *Music Information Retrieval*  
NB - Naïve Bayes  
PDS - Processamento de Sinais  
QBE - *Query-by-Example*  
QBH - *Query by Humming*  
RI - Recuperação de Informação  
RF – *Random Forest*  
RMS - *Root Mean Square*  
SciELO - *Scientific Electronic Library Online*  
SSD - Descritores Estatísticos de Espectro

STFT - *Short-Time Fourier Transform*

SVM - *Support Vector Machine*

UFG - Universidade Federal de Goiás

UFPR - Universidade Federal do Paraná

UFPE - Universidade Federal de Pernambuco

UFU - Universidade Federal de Uberlândia

WOS - *Web of Science*

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>14</b>
1.1	PROBLEMATIZAÇÃO .....	14
1.2	OBJETIVOS .....	16
1.2.1	Objetivo geral .....	16
1.2.2	Objetivos específicos.....	16
1.3	JUSTIFICATIVAS .....	16
1.3.1	Justificativa para a Ciência.....	17
1.3.2	Justificativa para a área da Gestão da Informação .....	20
1.3.3	Justificativa para o curso de Gestão da Informação da UFPR .....	21
1.3.4	Justificativa para o pesquisador .....	21
1.4	DELIMITAÇÃO DA PESQUISA.....	22
1.5	ESTRUTURA DO DOCUMENTO.....	22
<b>2</b>	<b>REFERENCIAL TEÓRICO.....</b>	<b>24</b>
2.1	RECUPERAÇÃO DE INFORMAÇÃO.....	25
2.2	RECUPERAÇÃO DE INFORMAÇÃO EM MÚSICA .....	27
2.3	PROCESSAMENTO DE SINAIS DE ÁUDIO.....	30
2.4	EXTRAÇÃO DE CARACTERÍSTICAS DE ÁUDIO .....	33
2.5	KDD (KNOWLEDGE DISCOVERY IN DATABASE) .....	38
2.6	MINERAÇÃO DE DADOS .....	40
2.6.1	Descoberta de Associação.....	41
2.6.2	Classificação .....	43
2.6.3	Regressão .....	47
2.6.4	Clusterização.....	48
2.7	MINERAÇÃO DE DADOS EM MÚSICA.....	49
<b>3</b>	<b>ENCAMINHAMENTOS METODOLÓGICOS .....</b>	<b>54</b>

3.1	CARACTERIZAÇÃO DA PESQUISA .....	54
3.2	MATERIAIS E MÉTODOS.....	55
3.2.1	Descritores obtidos no domínio do tempo .....	57
3.2.2	Descritores obtidos no domínio da frequência .....	58
3.2.3	Ferramentas de Mineração de Dados .....	60
3.3	BASES DE DADOS.....	61
3.3.1	Identificação das músicas .....	61
3.3.2	Tratamento dos arquivos.....	62
3.3.3	Extração dos descritores .....	63
3.4	ALGORITMOS .....	66
3.4.1	Random Forest.....	66
3.4.2	Bayes Net.....	67
3.4.4	K- Nearest Neighbor.....	67
3.4.5	Bagging e Boosting .....	67
<b>4</b>	<b>RESULTADOS.....</b>	<b>69</b>
4.1	RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL .....	69
4.1.1	Resultados para a base com duração original (Random Forest) .....	69
4.1.2	Resultados para a base com duração original (Bayes Net).....	71
4.1.3	Resultados para a base com duração original (KNN) .....	72
4.1.4	Resultados para a base com duração original (SVM) .....	73
4.1.5	Resultados para a base com duração original (Bagging) .....	74
4.1.6	Resultados para a base com duração original (Boosting) .....	75
4.2	RESULTADOS PARA A BASE COM DURAÇÃO DE 30 s.....	77
4.2.1	Resultados para a base com duração de 30 s (Random Forest) .....	77
4.2.2	Resultados para a base com duração de 30 s (Bayes Net) .....	78
4.2.3	Resultados para a base com duração de 30 s (KNN) .....	79
4.2.4	Resultados para a base com duração de 30 s (SVM) .....	80

4.2.5 Resultados para a base com duração de 30 s (Bagging).....	81
4.2.6 Resultados para a base com duração de 30 s (Boosting) .....	83
4.3 COMPARAÇÃO DOS RESULTADOS.....	84
<b>5 CONSIDERAÇÕES FINAIS .....</b>	<b>86</b>
5.1 VERIFICAÇÃO DOS OBJETIVOS PROPOSTOS.....	86
5.2 CONTRIBUIÇÕES .....	87
5.3 TRABALHOS FUTUROS .....	88
<b>REFERÊNCIAS.....</b>	<b>89</b>
<b>APÊNDICE A- LISTA DAS MÚSICAS UTILIZADAS NESTE ESTUDO .....</b>	<b>98</b>
<b>APÊNDICE B- TESTES PARA A BASE COM DURAÇÃO ORIGINAL .....</b>	<b>125</b>
<b>APÊNDICE C- TESTES PARA A BASE COM DURAÇÃO DE 30 s .....</b>	<b>126</b>
<b>APÊNDICE D- RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL (BAYES NET).....</b>	<b>127</b>
<b>APÊNDICE E- RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL (KNN) .....</b>	<b>128</b>
<b>APÊNDICE F- RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL (SVM) .....</b>	<b>129</b>
<b>APÊNDICE G- RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL (BAGGING).....</b>	<b>130</b>
<b>APÊNDICE H- RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL (BOOSTING).....</b>	<b>131</b>
<b>APÊNDICE I- RESULTADOS PARA A BASE COM DURAÇÃO DE 30 S (BAYES NET).....</b>	<b>132</b>
<b>APÊNDICE J- RESULTADOS PARA A BASE COM DURAÇÃO DE 30 S (KNN) .....</b>	<b>133</b>
<b>APÊNDICE K- RESULTADOS PARA A BASE COM DURAÇÃO DE 30 s (SVM) .....</b>	<b>134</b>
<b>APÊNDICE L- RESULTADOS PARA A BASE COM DURAÇÃO DE 30 s (BAGGING) .....</b>	<b>135</b>

APÊNDICE M- RESULTADOS PARA A BASE COM DURAÇÃO DE 30 s (BOOSTING).....	136
APÊNDICE N- COMPARAÇÃO DOS RESULTADOS OBTIDOS .....	137

## 1 INTRODUÇÃO

O ato de classificar é uma atividade presente em muitos momentos da vida humana. O ser humano classifica praticamente tudo a todo momento: com base na temperatura do dia, determina que o dia está frio ou quente; verificando o preço de um produto, o classifica como caro ou barato. A classificação, contudo, apesar de intrínseca ao ser humano, parece ser fruto de algum raciocínio lógico em que, determinadas variáveis (preço, temperatura, altura...) servem como parâmetro para divisão de certos elementos em categorias (caro, barato, quente, frio...) (PIRES, 2011).

Uma forma comum de se verificar o uso da classificação pelo ser humano é percebida na sua relação com a música: uma mesma música pode ser considerada boa por determinado grupo de pessoas e ruim por outro. A música soa como uma forma de expressão de sentimentos e, por conta disso, de acordo com a classificação que receba, será aplicada em diferentes situações e/ou compreendida de diferentes formas (CORREA, 2012).

Além do aspecto emocional, uma outra forma de associar músicas a momentos ou a sensações condiz ao gênero ao qual ela pertence (CORREA, 2012). Prova disso são os serviços de *streaming* que vendem boa parte de seus serviços baseados na personalização de conteúdo para seus usuários, personalização essa que, basicamente, consiste em agrupar músicas de gêneros semelhantes e que são consumidas por esses usuários. Graças a esses serviços, percebe-se um alto volume de informações musicais em formato digital circulando pela internet (SALAZAR, 2015).

Neste cenário, surge a área na qual está enquadrada esta pesquisa, conhecida como *Music Information Retrieval* (MIR), uma área destinada a recuperar músicas ou informações presentes em músicas de maneira eficaz e rápida (REZENDE, 2014).

### 1.1 PROBLEMATIZAÇÃO

Para Casey et al. (2008) os trabalhos relacionados à MIR têm sido objeto de pesquisa acadêmica e profissional, tendo como principais beneficiários três grandes públicos: a) indústria da música, responsável pela gravação e divulgação de músicas;

b) consumidores em busca de conteúdo personalizado; e c) profissionais ligados à música, tais como músicos, professores, musicólogos, advogados de direitos autorais e produtores musicais (CASEY et al., 2008).

Um dos principais objetivos destes estudos consiste na classificação automática de gêneros musicais. Para isto, a classificação, leva em consideração um vetor formado por descritores retirados diretamente do sinal de áudio digital por meio da conversão do sinal do domínio do tempo para o domínio da frequência. Essa conversão - realizada de forma mais comum pela aplicação da Transformada de Fourier - permite a obtenção de descritores como o timbre, as frequências fundamentais e o ritmo, geralmente responsáveis pela distinção entre gêneros musicais (MALHEIRO, 2003).

No que tange ao uso destes descritores, pode-se assumir que os trabalhos pioneiros foram desenvolvidos por Deshpande, Singh e Nam (2001) e por Tzanetakis e Cook (2002). Deshpande, Singh e Nam (2001) realizaram o seu estudo utilizando 157 músicas de três distintos gêneros (*rock*, música clássica e *jazz*) utilizando 12 coeficientes relacionados a *Mel-Frequency Cepstral Coefficients* (MFCC) e espectrogramas obtidos a partir do sinal do áudio. Para a tarefa de classificação, os algoritmos aplicados foram: a) *K-Nearest Neighbour* (KNN); b) Modelo Gaussiano; e c) *Support Vector Machine* (SVM).

O trabalho desenvolvido por Tzanetakis e Cook (2002) influenciou os estudos de classificação de gêneros musicais, uma vez que, os autores estabeleceram a classificação por meio de um conjunto de características relacionadas ao timbre, ao ritmo e à vibração, características normalmente aplicadas em outros trabalhos de mesma natureza. Outra contribuição deste trabalho consiste na base GTZAN, composta por segmentos de 30 segundos de 1000 músicas, de 10 diferentes gêneros: *blues*, música clássica, *country*, *disco*, *hip hop*, *jazz*, *metal*, *pop*, *reggae* e *rock*.

Ainda analisando trabalhos clássicos sobre o tema, citam-se os trabalhos desenvolvidos por Li, Ogihara e Li (2003); Grimaldi, Cunningham e Kokaram (2003) e Gjerdingen e Perrott (2008). No Brasil, destacam-se trabalhos como os elaborados por Costa, Valle e Koerich (2004); e Costa (2013).

Ao ter contato com estes estudos, verifica-se que ainda não há uma metodologia consolidada para a classificação de gêneros automaticamente, tanto no



que tange à extração de descritores, quanto aos algoritmos de Mineração de Dados empregados.

Sendo assim, a questão de pesquisa deste estudo consiste em: **de que forma classificar gêneros musicais de forma automática aplicando algoritmos de Mineração de Dados, considerando a análise de características extraídas do sinal de áudio?**

## 1.2 OBJETIVOS

Para responder ao problema de pesquisa deste estudo foram definidos os objetivos a serem alcançados com o projeto, sendo desmembrados em um objetivo geral e quatro objetivos específicos.

### 1.2.1 Objetivo geral

O objetivo geral consiste em classificar gêneros musicais automaticamente por meio da aplicação de algoritmos de Mineração de Dados, considerando a análise de características extraídas do sinal de áudio.

### 1.2.2 Objetivos específicos

O objetivo geral deste estudo desdobra-se nos seguintes objetivos específicos:

- a) identificar características que possam ser extraídas do sinal de áudio;
- b) extrair características do sinal de áudio de arquivos musicais;
- c) construir bases de dados compostas por um conjunto de arquivos com conteúdo musical;
- d) aplicar algoritmos de Mineração de Dados nas bases elaboradas.

## 1.3 JUSTIFICATIVAS

Com o intuito de fundamentar os motivos para o desenvolvimento desta pesquisa, subdividiu-se a justificativa em quatro itens, sendo estes:

### 1.3.1 Justificativa para a Ciência

Realizou-se uma pesquisa na coleção principal da base *Web of Science* (WOS) no dia 11 de março de 2017, com o objetivo de identificar a produção científica do Tema desta pesquisa. Ao total, foram realizadas cinco buscas, considerando todos os índices. Os resultados obtidos são descritos no Quadro 1.

QUADRO 1- RESULTADOS OBTIDOS NA BASE *WEB OF SCIENCE*

Busca	Termos	Total de Registros
1ª	"Data mining"	46.270
2ª	"Data mining" e "Music"	170
3ª	"Music genre classification"	159
4ª	"Data mining" e "Music classification"	6
5ª	"Data mining" e "Music genre classification"	5

FONTE: O autor. (2017)

Com relação aos resultados para o termo "*Data mining*", as 10 principais áreas responsáveis por pesquisas são representadas na Figura 1.

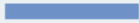









FIGURA 1- AS 10 PRINCIPAIS ÁREAS DE PESQUISA EM *DATA MINING*

Campo: Áreas de pesquisa	Contagem do registro	% de 46270	Gráfico de barras
COMPUTER SCIENCE	30757	66.473 %	
ENGINEERING	13685	29.576 %	
OPERATIONS RESEARCH MANAGEMENT SCIENCE	2477	5.353 %	
TELECOMMUNICATIONS	2368	5.118 %	
AUTOMATION CONTROL SYSTEMS	1979	4.277 %	
MATHEMATICS	1920	4.150 %	
BUSINESS ECONOMICS	1525	3.296 %	
BIOCHEMISTRY MOLECULAR BIOLOGY	1461	3.158 %	
MATHEMATICAL COMPUTATIONAL BIOLOGY	1276	2.758 %	
MEDICAL INFORMATICS	988	2.135 %	

FONTE: *Web of Science* (2017).

Com relação aos resultados obtidos para a pesquisa com os termos "*Data mining*" e "*Music*", as principais áreas são demonstradas na Figura 2.

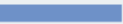








FIGURA 2- AS 10 PRINCIPAIS ÁREAS DE PESQUISA EM *DATA MINING* E *MUSIC*

Campo: Áreas de pesquisa	Contagem do registro	% de 170	Gráfico de barras
COMPUTER SCIENCE	132	77.647 %	
ENGINEERING	48	28.235 %	
MUSIC	15	8.824 %	
TELECOMMUNICATIONS	10	5.882 %	
NEUROSCIENCES NEUROLOGY	7	4.118 %	
PSYCHOLOGY	7	4.118 %	
MATHEMATICS	6	3.529 %	
ROBOTICS	6	3.529 %	
IMAGING SCIENCE PHOTOGRAPHIC TECHNOLOGY	5	2.941 %	
INFORMATION SCIENCE LIBRARY SCIENCE	5	2.941 %	

FONTE: *Web of Science* (2017).

Para a busca com o termo “*Music genre classification*”, as áreas com mais produções são demonstradas na Figura 3.

FIGURA 3- AS 10 PRINCIPAIS ÁREAS DE PESQUISA EM *MUSIC GENRE CLASSIFICATION*

Campo: Áreas de pesquisa	Contagem do registro	% de 159	Gráfico de barras
COMPUTER SCIENCE	116	72.956 %	
ENGINEERING	88	55.346 %	
ACOUSTICS	21	13.208 %	
TELECOMMUNICATIONS	20	12.579 %	
IMAGING SCIENCE PHOTOGRAPHIC TECHNOLOGY	18	11.321 %	
AUTOMATION CONTROL SYSTEMS	7	4.403 %	
OPERATIONS RESEARCH MANAGEMENT SCIENCE	4	2.516 %	
ROBOTICS	4	2.516 %	
MATHEMATICS	3	1.887 %	
MUSIC	2	1.258 %	

FONTE: *Web of Science* (2017)

Utilizando-se a combinação dos termos “*Data mining*” e “*Music classification*”, as áreas com a maior concentração de trabalhos são apresentadas na Figura 4.

FIGURA 4- AS PRINCIPAIS ÁREAS DE PESQUISA EM *DATA MINING* E *MUSIC CLASSIFICATION*

Campo: Áreas de pesquisa	Contagem do registro	% de 6	Gráfico de barras
COMPUTER SCIENCE	5	83.333 %	
AUTOMATION CONTROL SYSTEMS	1	16.667 %	
ENGINEERING	1	16.667 %	
MATHEMATICS	1	16.667 %	
ROBOTICS	1	16.667 %	

FONTE: *Web of Science* (2017)

Por fim, combinando os termos "*Data mining*" e "*Music genre classification*", as áreas com a maior concentração de estudos são representadas na Figura 5.

FIGURA 5- AS PRINCIPAIS ÁREAS DE PESQUISA EM *DATA MINING* E *MUSIC GENRE CLASSIFICATION*

Campo: Áreas de pesquisa	Contagem do registro	% de 5	Gráfico de barras
ENGINEERING	5	100.000 %	
COMPUTER SCIENCE	3	60.000 %	
ACOUSTICS	2	40.000 %	
AUTOMATION CONTROL SYSTEMS	1	20.000 %	

FONTE: *Web of Science* (2017)

Com base no conjunto formado pelas Figuras de 1 a 5, percebe-se a concentração dos trabalhos nas áreas de Engenharia e Ciência da Computação. Além disso, ressalta-se que há sobreposição de áreas no que tange à contagem de registros por áreas.

Outra pesquisa foi realizada na base *Scientific Electronic Library Online* (SciELO) com o objetivo de verificar publicações brasileiras relacionadas ao tema do presente estudo. Utilizando o termo "Mineração de dados", obteve-se um total de 158 registros. Combinando os termos "Mineração de dados" e "Música" nenhum registro foi encontrado. Ressalta-se que, para ambas as buscas, considerou-se todos os índices.

Uma terceira pesquisa foi realizada na base IEEE Xplore. Ao total, realizou-se cinco buscas considerando todos os itens. Os resultados obtidos são descritos no Quadro 2.

QUADRO 2- RESULTADOS OBTIDOS NA BASE IEEE XPLORE

Busca	Termos	Resultados
1ª	<i>"data mining"</i>	83.941
2ª	<i>"data mining" and "music"</i>	609
3ª	<i>"music genre classification"</i>	135
4ª	<i>"musical genre classification"</i>	35
5ª	<i>"data mining" and "music genre classification"</i>	21

FONTE: IEEE Xplore (2017).

Observando-se o Quadro 2, verifica-se a pouca quantidade de estudos que abordam os temas deste estudo (21 estudos), reforçando, dessa forma, a elaboração da presente pesquisa.

Considerando os resultados obtidos para os termos *"data mining"* e *"music genre classification"* nas bases WOS e IEEE Xplore, obteve-se 26 resultados. A fim de identificar possíveis repetições -materiais presentes nas duas bases-, realizou-se uma comparação entre estes resultados e, constatou-se a repetição de quatro resultados. Sendo assim, considera-se como resultado final 22 registros.

### 1.3.2 Justificativa para a área da Gestão da Informação

No dia 26 de março de 2017, realizou-se uma pesquisa nas bibliotecas de quatro universidades federais que ofertam o curso de Gestão da Informação, a saber: a) Universidade Federal do Paraná (UFPR); b) Universidade Federal de Pernambuco (UFPE); c) Universidade Federal de Uberlândia (UFU); e d) Universidade Federal de Goiás (UFG). O objetivo consistiu em identificar trabalhos com a temática deste estudo.

Na biblioteca do curso na UFPR, encontrou-se sete registros para *data mining*, e 10 registros para mineração de dados. Contudo, nenhum resultado com temática semelhante.

Na biblioteca da UFPE, pesquisou-se por mineração de dados e filtrou-se o resultado pela biblioteca de Artes e Comunicação - departamento ao qual pertence o curso de Gestão da Informação -, tendo como resultado apenas um registro. Ao analisar-se este registro, percebeu-se que sua temática não se assemelhava a do presente trabalho.

No sistema de bibliotecas da UFU, pesquisou-se por mineração de dados (48 registros) e por *data mining* (28 registros). Ao verificar-se os resultados, notou-se a falta de conteúdo relacionado às áreas de Gestão e Negócios - área a qual pertence Gestão da Informação -, e, portanto, não se encontrou material semelhante ao deste estudo.

Por fim, pesquisou-se no sistema de bibliotecas da UFG pelo termo “mineração de dados” e obteve-se um total de 40 registros. Ao se analisar estes, não se identificou registros relacionados à área de Gestão da Informação.

### 1.3.3 Justificativa para o curso de Gestão da Informação da UFPR

Efetou-se uma busca na base que concentra as monografias já desenvolvidas no curso de Gestão da Informação da UFPR, em busca de trabalhos realizados com a mesma temática do presente estudo. Utilizou-se como parâmetros de busca dois termos: *data mining*, sete registros obtidos; e mineração de dados, com um total de 10 registros. Nos resultados obtidos, nenhum possuía temática semelhante ao proposto neste estudo.

### 1.3.4 Justificativa para o pesquisador

Observou-se a falta de trabalhos com a temática proposta em estudos relacionados à Gestão da Informação e, por conta disso, objetiva-se contribuir para que, a partir deste estudo, novos pesquisadores despertem a vontade em elaborar estudos desta natureza, uma vez que, trata-se de uma nova abordagem de análise de dados que pode ser aproveitada em trabalhos de conclusão de cursos, projetos de

iniciação científica, conteúdo para disciplinas obrigatórias e optativas, além da possível continuação em estudos de nível de pós graduação, como mestrados e doutorados.

#### 1.4 DELIMITAÇÃO DA PESQUISA

A pesquisa abrangerá apenas a classificação de gêneros musicais, não tendo como objetivo outras tarefas como o reconhecimento de instrumentos musicais e análises relacionadas às letras musicais. Tendo em vista esta delimitação, alerta-se que não será utilizado a classificação levando em consideração arquivos no formato *Musical Instrument Digital Interface* (MIDI), uma vez que, este tipo de arquivo comumente é utilizado em tarefas que fogem do escopo desta pesquisa.

Esta pesquisa tem natureza quantitativa, frente a esta característica, não serão discutidas questões qualitativas referentes aos gêneros musicais, como elementos sócios-culturais e históricos presentes em cada um dos gêneros utilizados.

Com ciência das limitações da pesquisa, a próxima seção refere-se aos conceitos fundamentais para a compreensão do presente estudo.

#### 1.5 ESTRUTURA DO DOCUMENTO

O documento está dividido em cinco seções principais. A primeira seção corresponde à introdução, espaço em que se apresentam o problema de pesquisa, os objetivos, a delimitação e as justificativas desta pesquisa. A segunda seção corresponde à revisão da literatura pertinente relacionada ao tema abordado, em que se discutem a respeito da recuperação da informação e a recuperação da informação musical; processamento de sinais; extração de características do sinal de áudio, além dos conceitos de descoberta de conhecimento em base de dados (*Knowledge Discovery in Database*) e Mineração de Dados.

A terceira seção consiste nos encaminhamentos metodológicos; nesta seção apresenta-se a caracterização da pesquisa e os materiais e métodos - ferramentas, descritores e bases de dados - utilizados. A quarta seção abarca os resultados obtidos após a aplicação dos algoritmos de mineração de dados nas bases elaboradas.

Por fim, a quinta seção apresenta as considerações finais, destacando as dificuldades e contribuições do estudo, os resultados obtidos e a possibilidade da sua continuidade.



## 2 REFERENCIAL TEÓRICO

A seguir apresenta-se a fundamentação teórica dos principais conceitos utilizados neste estudo. Buscou-se por materiais como artigos de periódicos, livros, teses e dissertações que pudessem subsidiar o desenvolvimento da pesquisa a partir dos seguintes temas: recuperação de informação; recuperação de informação em música; processamento de sinais de áudio; extração de características de áudio, KDD (*Knowledge Discovery in Database*) e mineração de dados (*data mining*).

Como síntese dos materiais pesquisados - bem como dos autores - apresenta-se o quadro de referências deste estudo (QUADRO 3).

QUADRO 3- QUADRO DE REFERÊNCIAS

Conceitos	Suporte teórico
Recuperação da Informação	Lopes (2002); Ferneda (2003); Baeza-Yates e Ribeiro-Neto (2013).
Recuperação de Informação em Música	Tzanetakis (2002); Typke, Wiering e Velkamp (2005); Casey et al. (2008); Dorier (2011); Ujlambkar (2012); Rezende (2014).
Processamento de sinais de áudio	Cooley e Tukey (1965); Faria (1997); Haykin e Van Veen (2001); Malheiro (2003); Souza Filho (2006); Padovani e Freire (2006); Silva (2007); Castilho (2008); Piasecki Filho (2011); Bianchi (2012); Diniz, Silva e Netto (2014); Rezende (2014).
Extração de características de áudio	Deshpande, Singh e Nam (2001); Tzanetakis e Cook (2002); Li, Ogihara e Li (2003); Grimaldi, Cunningham e Kokaram (2003); Costa, Valle e Koerich (2004); Gjerdingen e Perrott (2008); Silla Junior, Kaestner e Koerich (2011); Costa (2013).
Descoberta de Conhecimento em Bases de Dados	Hu (1995); Fayyad, Piatetsky-Shapiro e Smyth (1996a); Fayyad, Piatetsky-Shapiro e Smyth (1996b); Fayyad, Piatetsky-Shapiro e Smyth (1996c); Tsunoda (2004).
Mineração de Dados	Quinlan (1986); Cendrowska (1987); Quinlan (1993); Agrawal, Imielinski e Swami (1993); Agrawal E Srikant (1994); John e Langley (1995); Dias (2002); Goldschmidt e Passos (2005); Two Crows Corporation (2005); Braga (2005); Vapnik (2006); Boente, Goldschmidt e Estrela (2008); Calil et al. (2008); Camilo e Silva

	(2008); Rokach e Maimon (2008); Dantas et al. (2008); Wu et al. (2008); Jain (2010); Linoff e Berry (2011); Correa (2012); Quilici-Gonzalez e Zampirolli (2014); Castro e Ferreira (2016).
Mineração de Dados em Música	Knopke (2004); Kuo et al. (2005); Xiao et al. (2008); Li; Li (2010); Li; Ogihara; Tzanetakis (2011).


FONTE: O Autor (2017).

A seguir apresenta-se a discussão a respeito de cada um dos conceitos elencados no Quadro 3.

## 2.1 RECUPERAÇÃO DE INFORMAÇÃO

Baeza-Yates e Ribeiro-Neto (2013) afirmam que a Recuperação de Informação (RI) tem como principal objetivo prover aos usuários acesso às informações que desejam; informações presentes em documentos, páginas *WEB*, objetos multimídia, etc. Ferneda (2003) argumenta que o termo “recuperação de informação” consiste em um processo que visa identificar em um *corpus* de um sistema quais destes atendem à necessidade informacional de um usuário, não se limitando à recuperação de dados. Os sistemas de RI devem recuperar informações capazes de satisfazer totalmente ou parcialmente às necessidades de informação dos seus usuários. Uma visão simplificada deste processo pode ser visualizada na Figura 6.

FIGURA 6- PROCESSO SIMPLIFICADO DE RECUPERAÇÃO DE INFORMAÇÃO



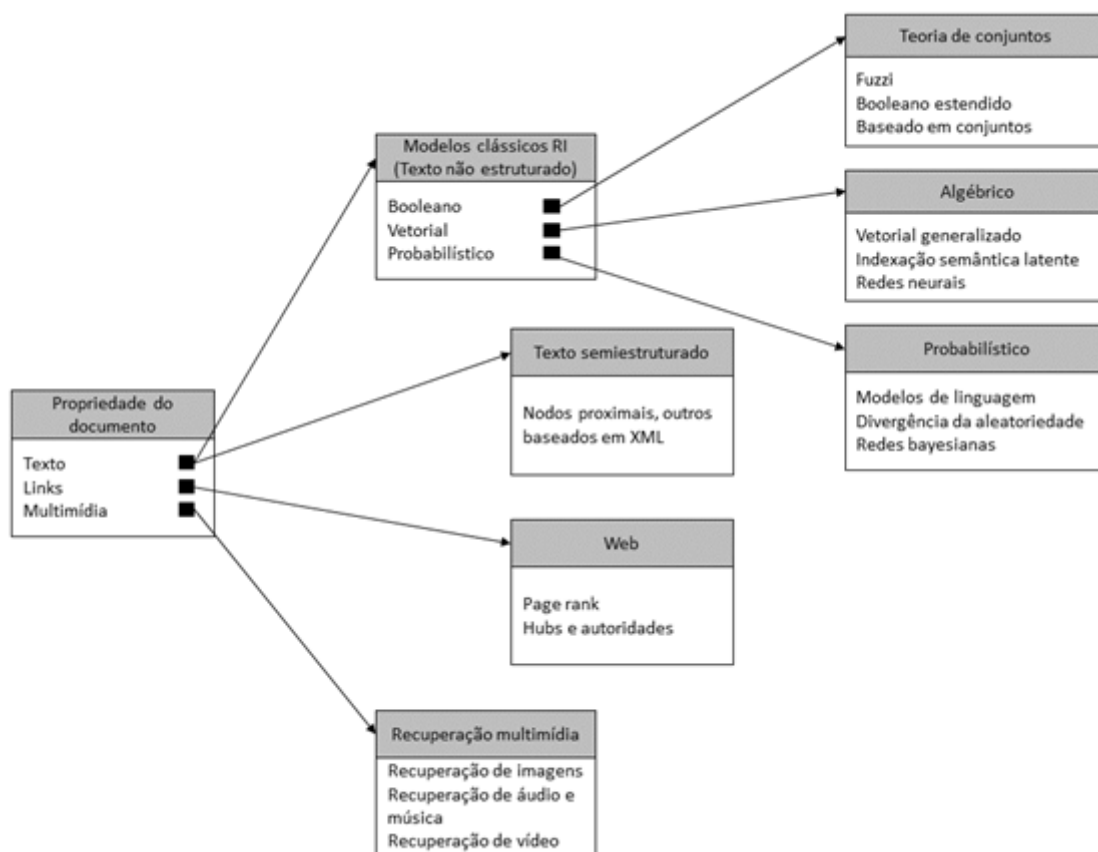
FONTE: Ferneda (2003, p. 13)

Lopes (2002) discorre que, no contexto da RI, a estratégia de busca de informação consiste em um conjunto de regras que visam encontrar respostas para uma pergunta formulada por um usuário. Neste contexto, o usuário deve traduzir sua

necessidade de informação “em uma consulta na linguagem fornecida pelo sistema” (BAEZA-YATES; RIBEIRO-NETO, 2013, p. 5).

No que tange aos sistemas de RI, o objetivo destes consiste em “recuperar todos os documentos que são relevantes à necessidade de informação do usuário e, ao mesmo tempo, recuperar o menor número de documentos irrelevantes” (BAEZA-YATES; RIBEIRO-NETO, 2013, p. 4). Tendo em vista as diversas necessidades que os usuários possuem, Baeza-Yates e Ribeiro-Neto (2013) elaboraram uma taxonomia para classificar os diferentes tipos de modelos de RI. Esta taxonomia é representada na Figura 7.

FIGURA 7- TAXONOMIA DOS MODELOS DE RI



FONTE: BAEZA-YATES; RIBEIRO-NETO (2013, p. 24)

Como visto na Figura 7, os autores diferenciam em três categorias os documentos: modelos baseados em textos, modelos baseados em *links* e modelos baseados em objetos multimídia.

A primeira categoria consiste nos modelos baseados em texto, divididos em texto semiestruturado e não estruturado. Aos textos não estruturados aplicam-se os modelos clássicos como: o modelo booleano (FERNEDA, 2003, p. 21); o modelo vetorial (FERNEDA, 2003, p. 28); e o modelo probabilístico (BAEZA-YATES; RIBEIRO-NETO, 2013, p. 48). Aos textos semiestruturados, aplicam-se técnicas de indexação como nodos proximais e os métodos de baseados em XML.

Quanto aos modelos baseados em *links*, dado ao grande volume de páginas, os modelos baseados em texto não são suficientes, sendo assim é necessária a adoção de métodos que considerem os *links* entre as páginas, tais como o *PageRank* (PAGE et. al, 1999).

A última categoria da taxonomia proposta por Baeza-Yates e Ribeiro-Neto (2013) consiste em documentos compostos por informações multimídias, que necessitam de estratégias diferenciadas por conta da natureza particular de cada tipo de mídia (imagens, músicas e vídeos).

## 2.2 RECUPERAÇÃO DE INFORMAÇÃO EM MÚSICA

A Recuperação de Informação em Música, também conhecida como MIR (*Music Information Retrieval*), tem como objetivo recuperar músicas ou informações presentes em músicas de uma maneira eficaz e rápida (REZENDE, 2014). Para Ujlambkar (2012), os resultados obtidos pelos sistemas de MIR auxiliam em aplicações que fornecem recomendações de músicas, semelhantes aos oferecidos por serviços de *streaming* como o Spotify<sup>1</sup> e o Deezer<sup>2</sup>.

De acordo com Dorier (2011), as pesquisas desta área caracterizam-se pela interdisciplinaridade, pois, incorporam conceitos e técnicas de áreas do conhecimento como a Ciência da Computação, a Musicologia e a Engenharia. Para Casey et al. (2008) estudos relacionados à recuperação de informações musicais têm sido objeto de pesquisa acadêmica e profissional, tendo como principais beneficiários três grandes públicos: a) indústria da música, responsável pela gravação e divulgação de músicas; b) consumidores em busca de conteúdo personalizado; e c) profissionais

---

<sup>1</sup> <https://www.spotify.com/br/>

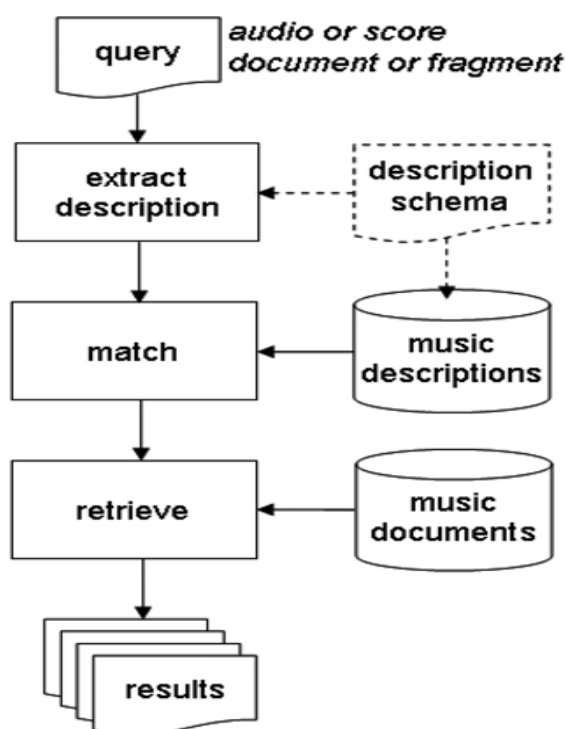
<sup>2</sup> <https://www.deezer.com/br/>

ligados à música, tais como músicos, professores, musicólogos, advogados de direitos autorais e produtores musicais (CASEY et al., 2008).

O processo de MIR pode considerar muitos aspectos diferentes no que tange à recuperação de informações. Casey et al. (2008) demonstram que é possível realizar a identificação de uma música utilizando um conjunto de metadados textuais geralmente criados baseados em opiniões de especialistas. Rezende (2014), por sua vez, argumenta que os sistemas de MIR podem, além dos metadados textuais, extrair um conjunto de características do conteúdo de áudio, criando assim uma assinatura única para cada música, ou, como o autor denomina, uma “impressão musical” (REZENDE, 2014, p.13).

As impressões musicais são armazenadas em banco de dados e, caso exista uma nova música a ser classificada, a impressão musical desta será criada e comparada com aquelas presentes no banco de dados. A partir desta comparação será criada uma pontuação - *score* - que será utilizado para identificar a qual música esta se assemelha (REZENDE, 2014). Este processo pode ser visualizado na Figura 8.

FIGURA 8- MODELO DO PROCESSO DE *MUSIC INFORMATION RETRIEVAL*



FONTE: Casey et. al. (2008)

Analisando a Figura 8, como resultado - ou saída – obtêm-se metadados, fragmentos ou gravações da música, dentre outras características (REZENDE, 2014).

Dentre as tarefas realizadas por meio dos sistemas de MIR, autores como Typke, Wiering e Veltkamp (2005) e Casey et al. (2008) elencam um conjunto de tarefas em seus respectivos trabalhos. Estas tarefas são observadas no Quadro 4.

QUADRO 4- PRINCIPAIS TAREFAS DOS SISTEMAS DE MIR

Tarefa	Descrição
Detectar plágio	A utilização inapropriada de ideias musicais desenvolvidas por outros artistas
Recomendar músicas	Recomendação de músicas que se assemelham ao perfil do usuário
Identificar músicas	Reconhecer a música que o usuário está ouvindo
Humor	Encontrar músicas que se adaptem a uma certa atmosfera emocional (melancolia, felicidade...)
Versão	Identificar diferentes versões da mesma música (ao vivo, acústica, cover)
Identificar compositores	Encontrar músicas de um determinado compositor
Estilo/Gênero	Identificação de músicas pertencentes a um determinado gênero musical
Instrumentos	Busca por músicas com os mesmos instrumentos musicais

FONTE: Adaptado de Typke, Wiering e Veltkamp (2005) e Casey et al. (2008)

Tzanetakis (2002) demonstra que a área de *Music Information Retrieval* foi construída em cima de algoritmos capazes de analisar as representações simbólicas dos arquivos de músicas, principalmente armazenados em arquivos do tipo *Musical Instrument Digital Interface* (MIDI), um formato em que as representações simbólicas se assemelham às partituras musicais, à medida que são constituídas por informações estruturadas detalhadas (TZANETAKIS, 2002).

De acordo com Tzanetakis (2002), as técnicas de recuperação de informações de músicas começaram a emergir como protótipos de pesquisa. Para o autor, os primeiros sistemas oriundos destes protótipos sustentavam-se em dois paradigmas: no primeiro, os sistemas tomam como entrada o som da voz humana - uma melodia - e, em seguida, recuperam arquivos de áudio semelhantes. Esta abordagem é

conhecida como *Query by Humming* (QBH). No segundo paradigma, conhecido como *Query-by-Example* (QBE), um arquivo de áudio é usado como entrada e arquivos de áudio com conteúdo semelhante são retornados de acordo com a sua similaridade (TZANETAKIS, 2002).

Segundo Tzanetakis (2002), o paradigma QBH tem a desvantagem de ser aplicado apenas quando o áudio está armazenado em arquivos MIDI, além de não ser aplicável em vários gêneros musicais, como a música eletrônica. Por sua vez, o paradigma QBE pode ser aplicado para procurar e recuperar sinais de áudio gerais, tais como arquivos mp3.

## 2.3 PROCESSAMENTO DE SINAIS DE ÁUDIO

Um sinal pode ser interpretado como “uma função de uma ou mais variáveis, a qual veicula informações sobre a natureza de fenômeno físico” (HAYKIN; VAN VEEN, 2001, p.22). No dia a dia é possível perceber sinais como elementos básicos do cotidiano, pois estes se manifestam, por exemplo, na comunicação humana - sinais da fala - e em situações que envolvem tomadas de decisão, como no caso de médicos que se utilizam dos sinais obtidos da audição de batimentos cardíacos, do monitoramento da pressão sanguínea e da temperatura de pacientes para realizar diagnósticos (HAYKIN; VAN VEEN, 2001).

Bianchi (2012) descreve que a área de Processamento de Sinais (PDS) é oriunda da Engenharia e tem como objetivos capturar, manipular e emitir sinais analógicos, preocupando-se, em particular, com os sinais analógicos temporais. De acordo com Rezende (2014) a área de PDS visa analisar e discretizar sinais por meio de técnicas e funções matemáticas para, assim, extrair informações ou adequá-los para posteriores aplicações específicas.

Tendo em vista a evolução da tecnologia nas últimas décadas, para Souza Filho (2006), a área de PDS pode-se utilizar de técnicas digitais como forma auxiliar à criação de funções e algoritmos sofisticados e que auxiliam os estudos que buscam realizar extração de dados e, posteriormente, utilizá-los em processamento de sinais.

O processamento digital de sinais encontra aplicação em diferentes aparelhos do cotidiano, tais como reprodutores de CDs, aparelhos de tomografia

computadorizada e aparelhos celulares (DINIZ; SILVA; NETTO, 2014). A respeito do processamento de sinais digitais, é possível verificar que a

possibilidade de amostragem e captura de uma representação discreta (com perda de informação) dos sinais analógicos e o advento do computador, que permite a representação e manipulação rápida de símbolos discretos, deram origem à área de processamento de sinais digitais. Muitas das ferramentas do domínio analógico estão presentes no domínio digital com as devidas adaptações e restrições (BIANCHI, 2002, p.1)

Com relação ao áudio, Silva (2007) afirma que, por conta do armazenamento em meios digitais, o processamento de sinais tornou-se uma área importante no que tange ao processamento de áudio, uma vez que, graças às características do meio digital, é possível editar e copiar dados sem grandes perdas, possibilitando a reprodução de arquivos de áudio idênticos, processo este que não ocorre no meio analógico.

Silva (2007) salienta que um sinal de áudio pode ser representado tanto no domínio do tempo, como no domínio da frequência. Levando estas características para a classificação de gêneros musicais - objetivo geral deste estudo -, percebe-se que é essencial possuir conhecimentos a respeito da frequência do sinal, posto que, desta forma, obtém-se fatores como o timbre, as frequências fundamentais e o ritmo, geralmente responsáveis pela distinção entre gêneros musicais (MALHEIRO, 2003).

Malheiro (2003) argumenta que é possível ter conhecimentos destes fatores caso converta-se o sinal do domínio do tempo para o domínio da frequência. Padovani e Freire (2006) descrevem em seu trabalho que a forma mais utilizada para realizar essa conversão é por meio da aplicação da Transformada de Fourier (TF).

A clássica transformada de Fourier, de acordo com Faria (1997) é conhecida desde a primeira metade do século XIX, e com sua utilização é

possível analisar digitalmente uma variedade de timbres de instrumentos musicais tradicionais, levando a uma melhor compreensão da natureza física e perceptual dos sons musicais, assim como à melhoria nas técnicas de síntese de som digital (FARIA, 1997, p. 67).

Autores como Castilho (2008) e Piasecki Filho (2011) exploram em seus respectivos trabalhos a aplicação da Transformada de Fourier como forma de se obter



o conteúdo harmônico de sinais por meio da análise do espectro das frequências que os caracterizam.

Além da Transformada de Fourier, Haykin e Van Veen (2001) demonstram que há outras formas distintas de se analisar sinais e que são derivadas das teorias desenvolvida por Joseph Fourier (1768-1830). Estas variações são amplamente utilizadas para se analisar sinais em áreas como as Engenharias e em diversos ramos da Ciência.

Uma breve representação dessas variações pode ser observada no Quadro 5.

QUADRO 5- RELAÇÃO ENTRE PROPRIEDADES DE TEMPO DE UM SINAL E A REPRESENTAÇÃO DE FOURIER APROPRIADA

Propriedade do Tempo	Periódica	Não periódica
Contínuo	Série de Fourier (FS)	Transformada de Fourier (FT)
Discreto	Série de Fourier de Tempo Discreto (DTFS)	Transformada de Fourier de Tempo Discreto (DFTT)

FONTE: Adaptado de Haykin e Van Veen (2001, p.165)

Como observa-se no Quadro 5 há quatro representações de Fourier distintas e que se aplicam a diferentes classes de sinais. As séries de Fourier aplicam-se aos sinais periódicos, sendo que, para os sinais periódicos de tempo contínuo utiliza-se a FS e para os discretos, a DTFS. Por sua vez, os sinais não-periódicos são representados pela Transformada de Fourier, sendo que, para os de tempo contínuo aplica-se a FT e, para os de tempo discreto tem-se a DFTT.

Além das representações descritas no Quadro 5, é possível citar, ainda, algoritmos desenvolvidos visando a otimização dos cálculos relacionados às teorias elaboradas por Fourier, principalmente no que tange às operações realizadas em computadores. O algoritmo conhecido como FFT (*Fast Fourier Transform*), foi desenvolvido por Cooley e Tukey (1965) e é considerado um marco no processamento de sinais e na análise musical, uma vez que, decompõe o espectro de frequências de um sinal sonoro rapidamente (CASTILHO, 2008).

Outro algoritmo frequentemente utilizado é conhecido como STFT (*Short-Time Fourier Transform*) e é baseado com base no FFT e que se caracteriza por dividir

o sinal em quadros menores e pela aplicação do FFT em cada um desses quadros (CASTILHO, 2008).

## 2.4 EXTRAÇÃO DE CARACTERÍSTICAS DE ÁUDIO

No que tange ao uso de características extraídas de sinais sonoros para classificação automática de gêneros musicais, pode-se assumir que os trabalhos pioneiros foram desenvolvidos por Deshpande, Singh e Nam (2001) e por Tzanetakis e Cook (2002).

Deshpande, Singh e Nam (2001) realizaram o seu estudo utilizando 157 músicas de 3 distintos gêneros (rock, música clássica e jazz) utilizando 12 coeficientes relacionados à *Mel-Frequency Cepstral Coefficients* (MFCC) e espectrogramas obtidos a partir do sinal do áudio. Para a tarefa de classificação, os algoritmos aplicados foram: a) *K-Nearest Neighbour* (KNN); b) Modelo Gaussiano; e c) *Support Vector Machine* (SVM).

O trabalho desenvolvido por Tzanetakis e Cook (2002) possui grande impacto nos estudos de classificação de gêneros musicais, uma vez que, os autores estabeleceram a classificação por meio de um conjunto de características relacionadas ao timbre, ao ritmo e à vibração, características que foram aplicadas em outros trabalhos de mesma natureza. Outra contribuição deste trabalho consiste na base GTZAN, composta por segmentos de 30 segundos de 1000 músicas, de 10 diferentes gêneros: *blues*, música clássica, *country*, *disco*, *hip hop*, *jazz*, *metal*, *pop*, *reggae* e *rock*.

Ainda analisando trabalhos clássicos sobre o tema, citam-se os trabalhos desenvolvidos por Li, Ogihara e Li (2003); Grimaldi, Cunningham e Kokaram (2003) e Gjerdingen e Perrott (2008). No Brasil, destacam-se trabalhos como os elaborados por Costa, Valle e Koerich (2004); Silla Jr, Kaestner e Koerich (2011) e Costa (2013).

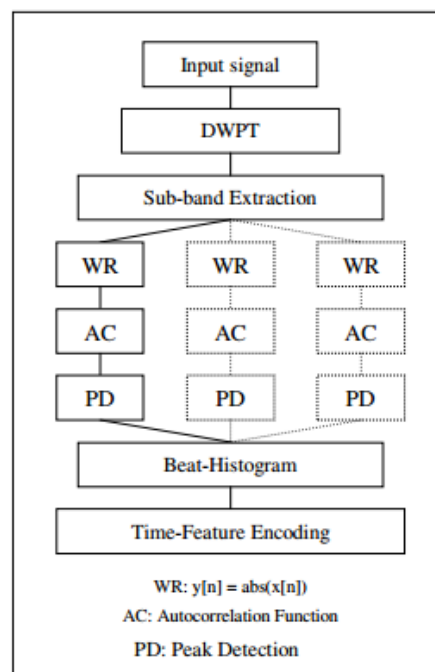
No trabalho de Li, Ogihara e Li (2003), os autores propuseram uma nova metodologia de extração de características baseada em informações obtidas por *Daubechies Wavelet Coefficient Histograms* (DWCHs). Para os experimentos, foram utilizados os métodos SVM e *Linear Discriminant Analysis* (LDA) em duas bases de

dados: a) GTZAN; e b) uma base composta por 756 músicas, de cinco gêneros: música ambiente, música clássica, *fusion*, *jazz* e *rock*.

Grimaldi, Cunningham e Kokaram (2003) em seu trabalho utilizaram para extrair as características do sinal a *Discrete Wavelet Packet Transform* (DWPT). Os autores aplicaram a DWPT em uma base de com 200 músicas, divididas em 5 gêneros musicais: *jazz*, música clássica, *rock*, *heavy metal* e *techno*. Para a classificação, o algoritmo utilizado foi o KNN.

O processo realizado por Grimaldi, Cunningham e Kokaram (2003) pode ser observado na Figura 9.

FIGURA 9- TIME-FEATURES EXTRACTION



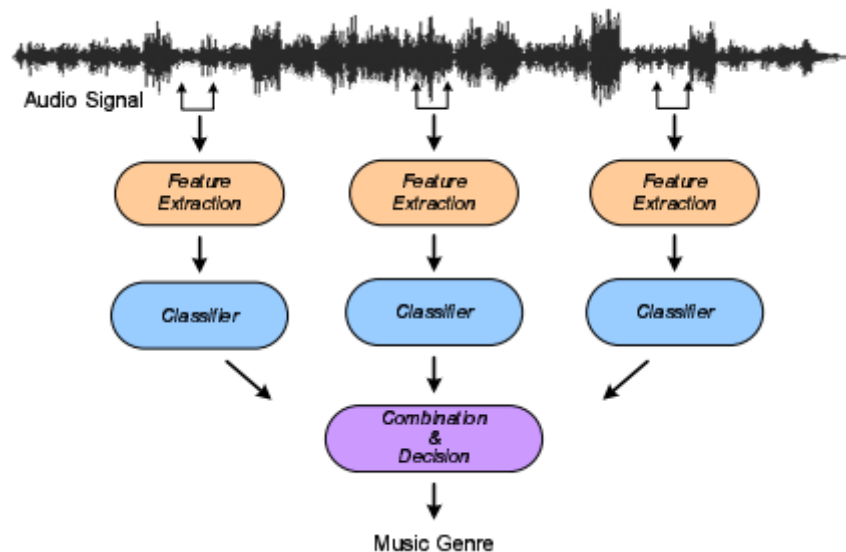
FONTE: Grimaldi, Cunningham e Kokaram (2003, p.103)

Gjerdingen e Perrott (2008) em seu estudo adotaram uma abordagem diferente para a classificação de gêneros musicais: os autores realizaram um experimento com 52 estudantes do primeiro ano de psicologia da *Northwestern University*, que afirmavam ser consumidores de músicas, consumindo, em média, 24,2 h de músicas por semana. Os autores conduziram este estudo mediante o uso de uma base composta por músicas pertencentes a 10 gêneros: *blues*, música clássica, *country*, *dance*, *jazz*, música latina, *pop*, *Rhythm and Blues*, *rap* e *rock*.

No âmbito nacional, Costa, Valle e Koerich (2004) conduziram uma classificação de gêneros musicais por meio de uma combinação de classificadores. Neste estudo, as características foram extraídas de três partes distintas de músicas em MP3, totalizando um vetor de 15 características de cada arquivo. As características utilizadas correspondem às propostas por Tzanetakis e Cook (2002) e, quanto à base utilizada, o total de arquivos corresponde a 414 músicas, dos gêneros *rock* e música clássica. Como algoritmos, os autores optaram por utilizar os algoritmos KNN e *Multilayer Perceptron* (MLP).

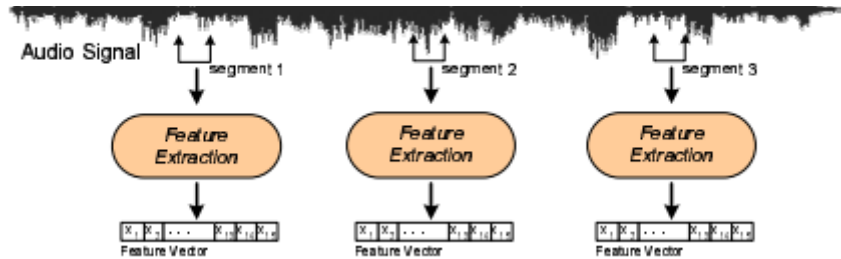
O processo adotado pelos autores pode ser visualizado nas Figura 10 e Figura 11.

FIGURA 10- VISÃO GERAL DO SISTEMA DE CLASSIFICAÇÃO PROPOSTO POR COSTA, VALLE E KOERICH (2004).



FONTE: Costa, Valle e Koerich (2004).

FIGURA 11- DEMONSTRAÇÃO DO PROCESSO DE EXTRAÇÃO DE CARACTERÍSTICAS



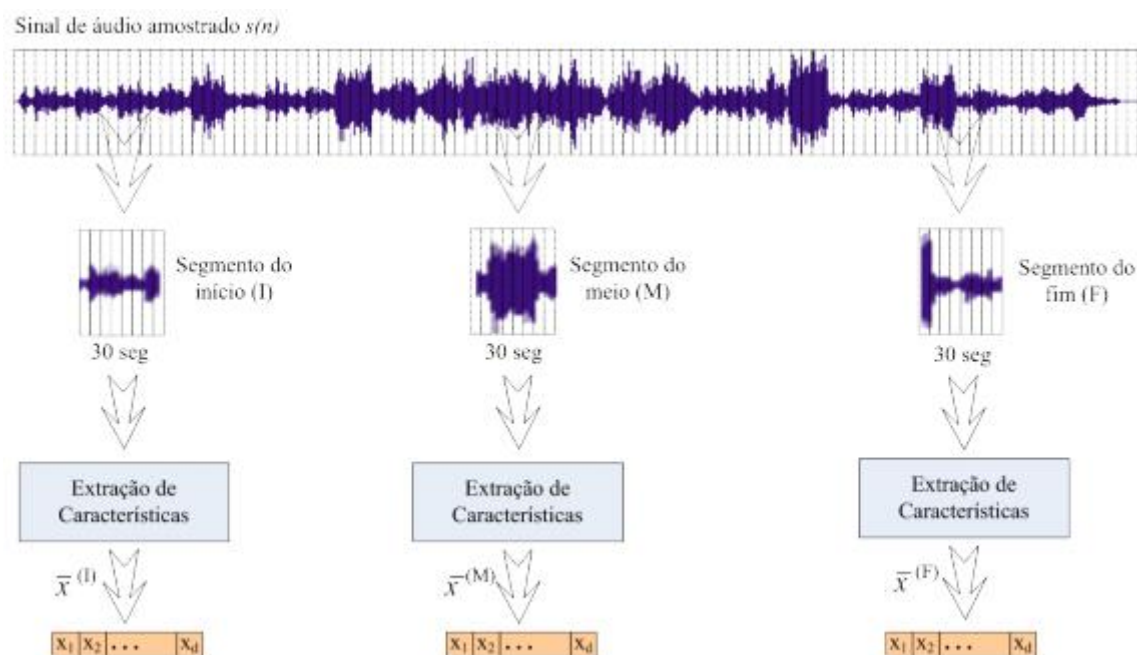
FONTE: Costa, Valle e Koerich (2004).

Silla Jr, Kaestner e Koerich (2011) realizaram seu estudo por meio de uma combinação de características baseadas no conteúdo do sinal, criando assim um vetor híbrido, composto por coeficientes do histograma de intervalos *Inset-Onset* (IOIHC), MARSYAS, histogramas de ritmo e descritores estatísticos de espectro (SSD).

Para os experimentos, o algoritmo escolhido pelos autores foi o SVM, e este foi utilizado para classificar arquivos oriundos de duas bases de dados: a) a *Latin Music Database* (LMD), uma base com 3.227 músicas de 10 gêneros musicais Latinos (axé, bachata, bolero, forró, gaúcha, merengue, pagode, salsa, sertaneja e tango); e b) a *ISMIR Genre 2004*, uma base composta por 1.458 músicas de seis gêneros musicais (música clássica, música eletrônica, *jazz & blues*, *metal & punk*, *rock & pop*, *world*).

O processo adotado pelos autores é representado na Figura 12.

FIGURA 12- EXTRAÇÃO DE CARACTERÍSTICAS



FONTE: Silla Jr, Kaestner e Koerich (2011).

O estudo desenvolvido por Costa (2013) trouxe uma abordagem baseada em imagens de espectrogramas obtidas diretamente do sinal do áudio. O autor utilizou a textura destes espectrogramas para realizar a classificação dos gêneros musicais, retirando destes descritores como o *Local Binary Pattern* e *Local Phase Quantization*. Os experimentos desenvolvidos por Costa (2013) foram realizados nas bases LMD e ISMIR 2004.

O estudo de Costa (2013) além de apresentar uma metodologia diferenciada para área em si, também apresenta uma significativa revisão de literatura a respeito de estudos já desenvolvidos com temáticas semelhantes, abordando a evolução da área e as diferentes metodologias já aplicadas.


## 2.5 KDD (KNOWLEDGE DISCOVERY IN DATABASE)

*Knowledge Discovery in Database* (KDD) - Descoberta de Conhecimento em Bases de Dados - pode ser compreendido como um processo de descobrimento de conhecimentos úteis a partir de uma grande quantidade de dados (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996a). Para Fayyad, Piatetsky-Shapiro e Smyth (1996b) a descoberta de conhecimento em bancos de dados é o processo, não trivial, de identificação de padrões válidos, novos e potencialmente úteis de dados.

Hu (1995) considera que o grande desafio do KDD consiste em processar grandes quantidades de dados brutos e identificar padrões significativos a partir destes, além disso, é preciso representá-los de uma forma significativa para que o usuário consiga atingir seu objetivo.

A visão tradicional do processo de KDD é demonstrada na Figura 13.

FIGURA 13- ETAPAS DO KDD



FONTE: Fayyad, Piatetsky-Shapiro e Smyth (1996c, p. 29).

O processo de KDD trata-se de um processo de natureza interdisciplinar, pois agrega conceitos e técnicas de áreas como aprendizado de máquinas, reconhecimento de padrões, banco de dados e estatística (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996b).


De acordo com Tsunoda (2004) o processo descrito no trabalho de Fayyad, Piatetsky-Shapiro e Smyth (1996c) é composto por sete passos básicos - conforme demonstrado na Figura 13. Sendo estes:

1. **Limpeza:** remoção de ruídos e, caso necessário, a exclusão de registros classificados como *outliers*, desconhecidos e valores nulos;

2. **Integração:** combinação de dados oriundos de fontes múltiplas em uma fonte comum;
3. **Seleção:** identificação dos dados relevantes;
4. **Transformação:** formatação dos dados para posterior aplicação da mineração de dados;
5. **Mineração de dados:** procura por padrões de interesse; manifesta-se em tarefas como regressão, agrupamento e regras de classificação;
6. **Avaliação:** interpretação dos padrões obtidos;
7. **Uso do conhecimento:** utilização do conhecimento adquirido em processos de tomada de decisão. (TSUNODA, 2004).

Tsunoda (2004) afirma que, apesar dos passos do processo serem apresentados de forma separada, na prática, alguns desses passos são executados de maneira conjunta, tais como a limpeza e a integração dos dados, que juntos são como um pré-processamento para a criação da base de dados a ser utilizada posteriormente na etapa de mineração de dados. Dada esta característica, o processo de KDD pode ser representado apenas por cinco etapas, conforme representado na Figura 14.

FIGURA 14- PROCESSO DE KDD COM CINCO ETAPAS



FONTE: Adaptado de Fayyad, Piatetsky-Shapiro e Smyth (1996c).

O processo de KDD pode ser compreendido como iterativo, uma vez que necessita de intervenção do usuário ao longo das etapas, bem como é também um processo iterativo, posto que possui uma sequência finita de passos (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996a).



## 2.6 MINERAÇÃO DE DADOS

Dentro do processo de KDD a Mineração de Dados (do inglês, *Data Mining*) é considerado a principal etapa para a descoberta de conhecimento. A Mineração de Dados pode ser compreendida como um processo que usa uma variedade de ferramentas de análise de dados para descobrir padrões e relacionamentos em dados para que seja possível realizar-se previsões válidas (TWO CROWS CORPORATION, 2005).

Rokach e Maimon (2008) definem a Mineração de Dados como sendo a ciência, a arte e a tecnologia de explorar grandes e complexos conjuntos de dados a fim de descobrir padrões úteis. Para Linoff e Berry (2011) Mineração de Dados consiste em um é um processo de negócios para a exploração de grandes quantidades grandes de dados com o objetivo de descobrir padrões e regras significativas.

Camilo e Silva (2008), consideram o processo de Mineração de Dados como fruto da cooperação entre homens e máquinas, cujo objetivo consiste na extração de conhecimentos por meio da análise de padrões e relacionamento entre variáveis de um grande conjunto de dados.

A Mineração de Dados de acordo com Dantas et al. (2008) visa procurar relações de similaridade ou discordância entre dados, para, assim, descobrir padrões, irregularidades e regras e, posteriormente, obter informações relevantes para a tomada de decisão e/ou avaliação de resultados.

Rokach e Maimon (2008) argumentam que a Mineração de Dados emergiu por conta da necessidade em se analisar com o exponencial crescimento de dados e informações, por conta disso, Boente, Goldschmidt e Estrela (2008) descrevem que existem diferentes tarefas de Mineração de Dados para suprir as diferentes necessidades relacionadas à análise de diferentes tipos de dados. As referidas tarefas são listadas abaixo:

- a) Descoberta de Associação;
- b) Classificação;
- c) Regressão;

- d) Clusterização;
- e) Sumarização;
- f) Detecção de Desvios;
- g) Descoberta de Sequências. (BOENTE; GOLDSCHMIDT; ESTRELA, 2008).

A seguir, nas próximas subseções serão detalhadas as tarefas de Mineração de Dados mais utilizadas em estudos: a) descoberta de associação; b) classificação; c) regressão; e d) clusterização (CASTRO; FERREIRA, 2016).

### 2.6.1 Descoberta de Associação

De acordo com Goldschmidt e Passos (2005) a tarefa de Descoberta de Associação (também conhecida como regras de associação) foi introduzida no trabalho desenvolvido por Agrawal, Imielinski e Swami (1993) que utilizaram esta tarefa em dados de vendas obtidos de uma grande companhia de varejo. Como objetivo, a descoberta de regras de associação visa encontrar conjuntos de itens que ocorrem de forma simultânea e frequente em banco de dados (GOLDSCHMIDT; PASSOS, 2005).

Li, Ogihara e Tzanetakis (2011) afirmam que o emprego da tarefa de descoberta de regras de associação visa detectar correlações entre diferentes itens em um conjunto de dados. Para os autores, esta tarefa tem recebido considerável atenção nas últimas décadas, graças à publicação dos algoritmos *ais* e *apriori* (AGRAWAL; SRIKANT, 1994).

Inicialmente, as pesquisas a respeito da descoberta de associação foram motivadas pela necessidade de empresas e comerciantes em compreender o comportamento de compra dos seus consumidores (LI; OGIHARA; TZANETAKIS, 2011); estas análises buscavam a descoberta de regras de associação entre os diferentes tipos de produtos comprados pelos clientes (GOLDSCHMIDT; PASSOS, 2005).

De forma simplificada, uma regra de associação pode ser representada da seguinte forma:  $X \rightarrow Y$ , sendo X e Y a representação de um conjunto de itens, em que

X representa o antecedente e Y o conseqüente. Um exemplo desta relação na vida real é exemplificado abaixo:

1. Leite  $\rightarrow$  Pão;
2. Pão  $\wedge$  Manteiga  $\rightarrow$  Café.

Com base na regra de número, assume-se que, se o produto adquirido for leite, então o outro produto adquirido será pão; com base na regra de número dois, verifica-se que, se os produtos adquiridos forem pão e manteiga, então café também será adquirido.

Srikant, Vu e Agrawal (1997) alertam que nem todas as regras descobertas em um banco de dados são consideradas válidas, uma vez que, as regras geradas devem respeitar duas medidas mínimas importantes: a) suporte; e b) confiança.

O suporte de uma regra consiste na frequência em que um determinado padrão aparece em todo o conjunto de dados. Por exemplo, para se calcular o suporte para a regra  $(A \rightarrow B)$ , utiliza-se a Equação 1.

$$S(A \rightarrow B) = \frac{(A \cup B)}{N} \quad (1)$$

Por sua vez, a confiança de uma regra consiste no número de vezes em que  $(A \cup B)$  ocorre em relação ao número em que A ocorre. Sendo assim, a confiança de uma regra é calculada pela Equação 2.

$$C(A \rightarrow B) = \frac{(A \cup B)}{(A)} \quad (2)$$

Dentre os algoritmos utilizados nesta tarefa, destaca-se o algoritmo *apriori* (AGRAWAL; SRIKANT, 1994). O algoritmo é um dos mais utilizado em estudos de Mineração de Dados, a prova disso é a quarta colocação na lista dos 10 principais algoritmos de Mineração de Dados (WU et al., 2008).

## 2.6.2 Classificação

Classificação é a tarefa de atribuir determinados objetos a uma categoria predefinida (LI; OGIHARA; TZANETAKIS, 2011). Nesta tarefa, de acordo com Goldschmidt e Passos (2005) busca-se associar corretamente cada um dos exemplos de um conjunto  $X_i$  a um rótulo categórico  $Y_i$ , conhecido como classe.

Correa (2012, p.51) descreve que classificar, em termos gerais, “significa associar amostras observadas às classes ou categorias de acordo com as propriedades que elas apresentam”.

Dias (2002) apresenta a sua visão para a tarefa de classificação. Para a autora, nesta tarefa, o objetivo é a construção de um modelo que possa categorizar dados não classificados em classes. Para isso, busca-se uma relação entre o atributo meta e os atributos previsores dentro de um conjunto de dados.

Para a tarefa de classificação, necessita-se compreender dois conceitos importantes e que influenciam o desempenho dos resultados obtidos: a) dados de treinamento; e b) dados de teste (CALIL et al., 2008).

A diferença entre os dados de treinamento e os dados de teste é descrita por Calil et al. (2008): os dados de treinamento consistem na construção de um modelo de classificação baseado em um conjunto de dados que, posteriormente, serão aplicados para classificar outros dados. O conjunto de dados não contemplados neste modelo são denominados dados de teste.

Além do conceito de dados de treinamento e dados de teste, outro ponto importante para a tarefa de classificação consiste na escolha do algoritmo. Castro e Ferrari (2016) afirmam que para classificar um objeto é necessário o uso de um algoritmo para a construção de um modelo de classificação, o qual também é denominado classificador. Os autores afirmam existir uma gama variada de algoritmos e, por conta disso, estes são agrupados da seguinte maneira:

1. baseados em conhecimento;
2. baseados em árvores;
3. conexionistas;
4. Baseados em distância;
5. Baseados em função;
6. Probabilísticos. (CASTRO; FERREIRA, 2016, p. 269-271)

O modelo baseado em conhecimento é baseado em um conjunto de regras para atribuir uma classe a determinado objeto, desde que ele satisfaça alguma condição predefinida. A representação deste modelo é representada na Figura 15.


FIGURA 15- MODELO BASEADO EM CONHECIMENTO.



FONTE: Castro e Ferreira (2016, p.269)

Modelos baseados em árvores são aqueles em que a classificação é realizada de forma que as relações entre os objetos formam a estrutura de uma árvore: nó raiz (testes de um atributo), ramos (resultados dos testes) e folhas (rótulos de classe). Estes modelos são amplamente utilizados nas tarefas de classificação. A representação deste modelo pode ser visualizada na Figura 16.


FIGURA 16- MODELO BASEADO EM



FONTE: Castro e Ferreira (2016, p.269)

Classificadores que seguem o tipo conexionistas caracterizam-se pela presença de nós interconectados e são considerados um tipo de grafo. Um exemplo deste modelo é apresentado na Figura 17.

FIGURA 17- MODELO CONEXIONISTA.



FONTE: Castro e Ferreira (2016, p.270)

Os classificadores baseados em distância são aqueles em que a classificação é realizada por meio do cálculo da distância entre o objeto a ser classificado em relação às classes. Neste caso, o objeto pertencerá à classe com a menor distância dele.

A representação deste classificador é representada na Figura 18.

FIGURA 18- MODELO BASEADO EM DISTÂNCIA.




FONTE: Castro e Ferreira (2016, p.270)

Modelos baseados em função são aqueles cuja classificação ocorre por meio de funções predefinidas, em que os parâmetros são ajustados durante a etapa de treinamento. Nestes modelos, após o treinamento, o objeto com classe desconhecida

será submetido à função predefinida e, posteriormente, associado a uma classe. A demonstração de um modelo baseado em função é apresentada na Figura 19.

FIGURA 19- MODELO BASEADO EM FUNÇÃO.



FONTE: Castro e Ferreira (2016, p.270)

Os modelos probabilísticos caracterizam-se por trabalhar com a probabilidade de um objeto pertencer a um número de classes. A representação deste modelo é observada na Figura 20.

FIGURA 20- MODELO PROBABILÍSTICO.



FONTE: Castro e Ferreira (2016, p.271)

Apesar de fazerem estas divisões quantos aos modelos de classificadores, Castro e Ferreira (2016) afirmam que, na prática, estas categorias não são

mutuamente exclusivas, posto que, por exemplo, modelos baseados em árvores são interpretados como sistemas baseados em regras, assim como um modelo baseado em função pode ser interpretado como um modelo probabilístico.

Dentre os algoritmos mais utilizados para a tarefa de classificação, destacam-se: 1) KNN (CASTRO e FERREIRA, 2016), um algoritmo não paramétrico baseado em distância; 2) C4.5 (QUINLAN, 1993), algoritmo para indução de árvores e que é uma evolução de outro algoritmo para a geração de árvores de decisão, o ID3 (QUINLAN, 1986); 3) PRISM (CENDROWSKA, 1987), algoritmo que gera regras de classificação como saída; 4) Naïve Bayes (NB) (JOHN e LANGLEY, 1995), classificadores estatísticos fundamentados no Teorema de Bayes; e 5) SVM (VAPNIK, 2006), algoritmo baseado em função e que busca a separação de dados em duas classes.

Outro ponto interessante a ser citado corresponde ao fato de que, dos 10 algoritmos mais utilizados em Mineração de Dados (WU et al., 2008), cinco correspondem à tarefa de classificação: C4.5 (1º); SVM (3º); KNN (8º); NB (9º); e *Classification and Regression Trees* (CART) (10º).

### 2.6.3 Regressão

A tarefa de Regressão, em Mineração de Dados, consiste na busca por funções que possam descrever determinadas relações entre variáveis de um banco de dados (GOLDSCHMIDT; PASSOS, 2005). Em linha gerais, a regressão visa identificar a “relação entre uma ou mais variáveis de resposta (também chamadas de variáveis de saída, dependentes, preditas ou explicadas) e os preditores (também chamados de variáveis de controle, independentes, explanatórias ou regressores)” (CASTRO; FERREIRA, 2016, p. 325)

A forma mais simples de regressão é a regressão linear, na qual buscam-se relações entre duas variáveis, por meio de uma equação de linha reta que representa da melhor forma essa relação (CASTRO; FERREIRA, 2016). A regressão é calculada pela Equação 3.



$$y = ax + b \quad (3)$$

Na Equação 3,  $y$  corresponde à variável dependente, e  $x$ , à variável independente. Para Castro e Ferreira (2016) a regressão linear, deriva-se de métodos estatísticos, que modelam a relação entre uma variável dependente e uma ou mais independentes. Caso essa relação seja estabelecida com apenas uma variável independente, assume-se que se trata de uma regressão simples.

Além da regressão linear, Braga (2005) apresenta os modelos de regressão não-linear, menos utilizados dos que os lineares. Dentre os motivos para a pouca aplicação estão: a) a dificuldade em se encontrar uma solução, uma vez que, esta é fruto de um processo iterativo e não por uma expressão matemática explícita; e b) a necessidade em se selecionar o modelo antes das variáveis, procedimento que é difícil de ser justificado.

Além dos modelos de regressão linear e não-linear, há outros modelos como o modelo de regressão logística (BRAGA, 2005) e o modelo de regressão polinomial (CASTRO; FERREIRA, 2016).

#### 2.6.4 Clusterização

A tarefa de clusterização (ou agrupamento) consiste na separação de objetos em grupos (*clusters*) semelhantes (CASTRO; FERREIRA, 2016). Nesta tarefa, um conjunto de dados é segmentado em grupos com características similares e, diferentemente da tarefa de classificação, não há classe predefinidas, sendo o critério de agrupamento é a similaridade dos atributos ou das características dos registros (QUILICI-GONZALEZ; ZAMPIROLI, 2014).

Graças a esta característica, o processo de agrupamento é conhecido como não supervisionado, também denominado como aprendizagem não supervisionada (CASTRO; FERREIRA, 2016)

Castro e Ferreira (2016) descrevem que, em um processo de agrupamento, procura-se maximizar a similaridade intraclasse e minimizar a similaridade interclasse, ou seja, um cluster pode ser compreendido sendo a “uma coleção de objetos similares

uns aos outros e dissimilares aos objetos pertencentes a outros clusters” (CASTRO; FERREIRA, 2016, p.42).

Goldschmidt e Passos (2005) consideram que, apesar de ser uma tarefa cuja aprendizagem é não supervisionada, esta tarefa requer que o usuário determine o número de grupos. Com base neste número, é possível aplicar algoritmos que busquem encontrar k-centroides de clusters, de uma forma que, a distância de cada ponto de dados seja a menor possível da centroide do cluster mais próximo.

Dentre os métodos de clusterização, dois se destacam: a) métodos por particionamento; e b) métodos hierárquicos (GOLDSCHMIDT; PASSOS, 2005). Os métodos por particionamento são aqueles em que cada cluster contém somente elementos similares entre si, gerando agrupamentos simples (GOLDSCHMIDT; PASSOS, 2005).

Os métodos hierárquicos, por sua vez, decompõem a base de dados de forma hierárquica, formando a figura de um dendograma, uma árvore em que de forma iterativa divide a base de dados em subconjuntos até que cada subconjunto conte com apenas um objeto (GOLDSCHMIDT; PASSOS, 2005).

Como algoritmo de agrupamento, destaca-se o algoritmo *k-means* (JAIN, 2010), um algoritmo amplamente utilizado em Mineração de Dados, sendo considerado o segundo mais utilizado de acordo com o estudo de Wu et al. (2008).

## 2.7 MINERAÇÃO DE DADOS EM MÚSICA

A Mineração de Dados em Música (do inglês, *Music Data Mining*) envolve a aplicação das tarefas usuais de Mineração de Dados em contextos particulares como a identificação de artistas / cantores, reconhecimento de instrumentos, descoberta de similaridade entre músicas, entre outras tarefas (LI; LI, 2010).

Li, Ogihara e Tzanetakis (2011) compilaram em seu trabalho algumas relações entre as tarefas de Mineração de Dados e a aplicação destas nos estudos relacionados à música. Essa compilação é representada no Quadro 6.

QUADRO 6- APLICAÇÕES DAS TAREFAS DE MINERAÇÃO DE DADOS NA MÚSICA

<b>Tarefas de Mineração de Dados</b>	<b>Aplicação na Música</b>
Associação	Associação de músicas
Classificação	Classificação de áudio
	Classificação de gênero musical/estilo
	Classificação de artistas
	Identificação de cantores
	Detecção de humor
	Reconhecimento de instrumentos
Agrupamento	Agrupamento
Busca por similaridades	Busca por similaridades em músicas
Sumarização	Sumarização de músicas

FONTE: Adaptado de Li, Ogihara e Tzanetakis (2011, p.15)

Para Li e Li (2010) a descoberta de associação em músicas pode ser dividida em três categorias: i) detecção de associações levando em consideração diferentes características acústicas (XIAO et al., 2008); ii) detectar associações entre a música e outros formatos de documentos (KNOPKE, 2004); e iii) detecção de associações entre as características musicais e outros aspectos musicais, como emoções (KUO et al., 2005).

A tarefa de classificação merece destaque nos estudos de Mineração de Dados em Músicas, graças ao emergente número de trabalhos com essas temáticas nas últimas décadas (LI; OGIHARA; TZANETAKIS, 2011). Dentre os estudos que fazem uso desta tarefa, muitos objetivam a classificação de gênero ou estilo musical, contudo, os estudos não se limitam apenas a esta classificação; objetivos como a classificação de artistas/ cantores, classificação de humor e de instrumentos também estão presentes em trabalhos de classificação (LI; OGIHARA; TZANETAKIS, 2011).

Uma representação dos principais objetivos, bem como das técnicas utilizadas nos estudos de classificação musical é apresentada no Quadro 7.

QUADRO 7- TAREFAS E TÉCNICAS PARA A CLASSIFICAÇÃO DE MÚSICAS

<b>Tarefas</b>	<b>Técnicas</b>
Classificação de áudio	<i>Tree-based Quantization</i>
	<i>Covariance Matrix</i>
	<i>Hidden Markov Model</i>
Classificação de gênero musical	Bayesian Model
	<i>Decision Tree</i>
	<i>Hidden Markov Model</i>
	<i>Statistical Pattern Recognition</i>
	<i>Wavelet Transformation</i>
	<i>Support Vector Machine</i>
	<i>Taxonomy</i>
	<i>Multi-labeling Classification</i>
	<i>Neural Network</i>
Classificação de artistas	<i>Singer Voice</i>
	<i>Text Categorization</i>
Identificação do cantor (a)	<i>Gaussian Mixture Model</i>
	<i>K-Nearest Neighbour</i>
Identificar o humor	<i>K-Nearest Neighbour</i>
	<i>SVM on Text Features</i>

	<i>Multi-label Classification</i>
	<i>Fuzzy Classifier</i>
	<i>Gaussian Mixture Model</i>
Reconhecimento de instrumentos	<i>Statistical Model</i>
	<i>Neural Networks</i>
	<i>Prior Knowledge</i>
	<i>Taxonomy</i>

FONTE: Adaptado de Li, Ogihara e Tzanetakis (2011, p.21)

A classificação de áudio consiste, tradicionalmente, em identificar e classificar o áudio em três classes: i) fala; ii) música; e iii) som ambiental (LI; OGIHARA; TZANETAKIS, 2011). Na classificação de gênero musical, Li, Ogihara e Tzanetakis (2011) relatam que a classificação automática é baseada em três conjuntos de características diferentes, relacionadas com características do ritmo, *pitch* e timbre.

A identificação e a classificação do humor descrevem os aspectos emocionais de uma música (LI; OGIHARA; TZANETAKIS, 2011); o reconhecimento e a classificação de instrumentos musicais auxiliam na identificação de quais instrumentos são utilizados em trilhas sonoras, orquestras, levando em consideração aspectos relacionados a padrões melódicos e estruturas harmônicas ou rítmicas (LI; LI, 2010).

Li e Li (2010) descrevem que a classificação de artistas se baseia, tradicionalmente, em características acústicas ou relacionadas à voz do cantor. A identificação de cantores auxilia na organização, busca e recuperação de dados em grandes coleções de músicas, sendo de grande valia para a indexação e recuperação de músicas em sistemas de recomendação de música (LI; LI, 2010)

Retornado às tarefas de Mineração de Dados e suas aplicações em estudos relacionados à música, Li e Li (2010) afirmam que a tarefa de agrupamento visa dividir uma coleção de dados de musicais em grupos de objetos semelhantes com base em suas similaridades. A tarefa de sumarização musical, assim como a sumarização do

texto, tem como objetivo encontrar temas mais comuns dentro de uma determinada peça de música (LI; LI, 2010).

Após a apresentação dos principais conceitos, a próxima seção aborda os encaminhamentos metodológicos do presente estudo.

### 3 ENCAMINHAMENTOS METODOLÓGICOS

Esta seção apresenta a caracterização da pesquisa e os materiais e métodos necessários para a extração de características e mineração de dados, bem como a descrição da base de dados do estudo.

#### 3.1 CARACTERIZAÇÃO DA PESQUISA

Esta pesquisa tem natureza quantitativa, pois objetiva-se a coleta e análise quantitativa de dados relacionados às características do sinal digital de áudio como forma de se atingir o objetivo geral estabelecido.

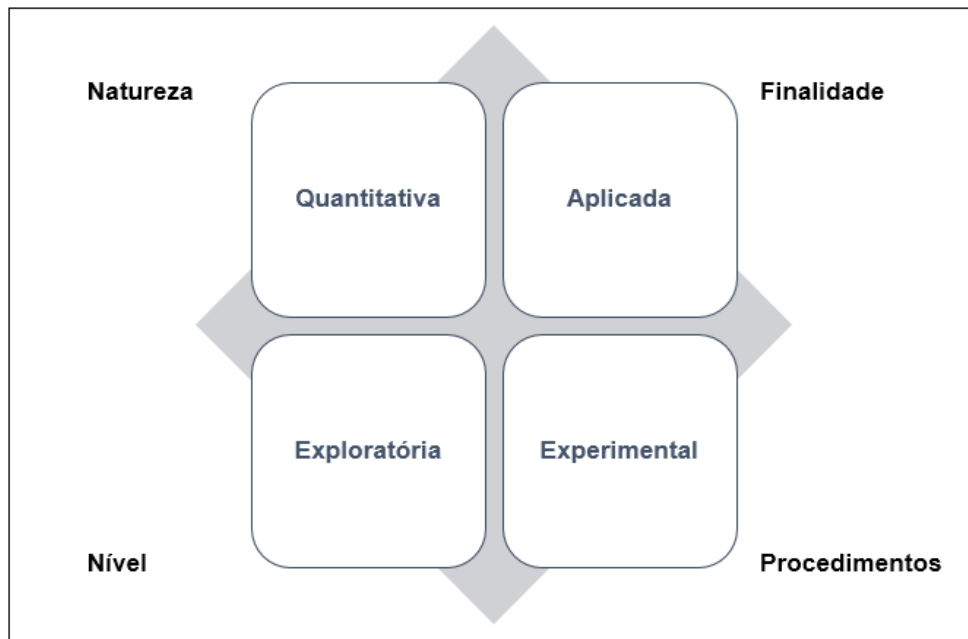
No que tange à sua finalidade, assume-se que se trata de uma pesquisa aplicada, uma vez que, busca-se uma aplicação prática para o problema levantado neste estudo (GIL, 2008).

Quanto ao nível, classifica-se esta pesquisa como exploratória, posto que, busca-se discutir uma temática pouco explorada no contexto da Gestão da Informação, além de proporcionar problemas ou hipóteses para estudos posteriores (GIL, 2008).

Por fim, quanto aos procedimentos, este estudo é caracterizado como experimental, posto que, a partir de um objeto de estudo, pretende-se selecionar as variáveis capazes de influenciá-lo a fim de observar-se os efeitos destas no objeto (GIL, 2008).

A Figura 21 sintetiza a caracterização da pesquisa.

FIGURA 21- SÍNTESE DA CARACTERIZAÇÃO DA PESQUISA.




FONTE: O autor (2017).

A seguir descreve-se os materiais e os métodos necessários para a realização deste estudo.

### 3.2 MATERIAIS E MÉTODOS

A metodologia deste estudo consiste, basicamente, no processo denominado *Knowledge Discovery in Databases* (KDD), proposto por Fayyad, Piatetsky-Shapiro e Smyth (1996c). As etapas deste processo são sintetizadas na Figura 22.

FIGURA 22- PROCEDIMENTOS METODOLÓGICOS: KDD.



FONTE: Adaptado de Fayyad, Piatetsky-Shapiro e Smyth (1996c).



O primeiro passo consistiu na seleção de músicas para o estudo: identificou-se as 150 músicas mais populares de sete gêneros (*rock, jazz, pop*, música clássica, MPB, *heavy metal* e samba) da *Last.fm* e, posteriormente, retirou-se as do Youtube. Nesta etapa almejou-se utilizar o Spotify, contudo, o uso desta plataforma demonstrou-se inviável. Desta forma, construiu-se uma base com 1.050 arquivos.

Optou-se identificar as músicas mais populares na *Last.fm* por esta ser uma plataforma sustentada no compartilhamento e recomendação de músicas (AMARAL; AQUINO, 2009). Além disso, a plataforma concentra estações de rádio, possui fóruns para discussões entre os membros e um sistema de *tags* feito pelos próprios usuários (AMARAL; AQUINO, 2009).

Amaral e Aquino (2009) afirmam que graças a estas características, a *Last.fm* é uma grande base de dados, composta por dados de artistas dos mais diversos gêneros musicais. Os dados que compõem a base são obtidos mediante a análise do que os usuários escutam por meio de um processo chamado “*scrobbler*”, que faz a leitura das músicas que o usuário escuta e as publica no seu perfil. (AMARAL; AQUINO, 2009).

Para se extrair as características do sinal do áudio dos arquivos selecionados, foi necessário identificar quais ferramentas poderiam realizar este procedimento. As ferramentas identificadas são listadas no Quadro 8.

QUADRO 8- FERRAMENTAS PARA EXTRAÇÃO DE CARACTERÍSTICAS DO SINAL DO ÁUDIO.

Nome	Site	Linguagem de programação
<i>Auditory Toolbox</i>	<a href="https://engineering.purdue.edu/~malcolm/interval/1998-010/">https://engineering.purdue.edu/~malcolm/interval/1998-010/</a>	MATLAB
<i>CLAM</i>	<a href="http://clam-project.org/">clam-project.org/</a>	C++
<i>D. Ellis Code</i>	<a href="http://www.ee.columbia.edu/~dpwe/resources/matlab/">http://www.ee.columbia.edu/~dpwe/resources/matlab/</a>	MATLAB
<i>HTK</i>	<a href="http://htk.eng.cam.ac.uk/">htk.eng.cam.ac.uk/</a>	C++
<i>JAudio</i>	<a href="http://jmir.sourceforge.net/jAudio.html">http://jmir.sourceforge.net/jAudio.html</a>	Java
<i>Marsyas</i>	<a href="http://marsyas.info/">http://marsyas.info/</a>	C++/Python
<i>MA Toolbox</i>	<a href="http://www.pampalk.at/ma/">http://www.pampalk.at/ma/</a>	MATLAB

<i>MIR Toolbox</i>	<a href="https://www.mathworks.com/matlabcentral/fileexchange/24583-mirtoolbox?requestedDomain=www.mathworks.com">https://www.mathworks.com/matlabcentral/fileexchange/24583-mirtoolbox?requestedDomain=www.mathworks.com</a>	MATLAB
<i>Sphinx</i>	<a href="https://cmusphinx.github.io/">https://cmusphinx.github.io/</a>	C++
<i>VAMP Plugins</i>	<a href="http://www.vamp-plugins.org">www.vamp-plugins.org</a>	C++

FONTE: Adaptado de Li, Ogihara e Tzanetakis (2011, p.68)

Optou-se pela escolha da ferramenta *jAudio*, pois é uma ferramenta *open source*, oriunda de um projeto denominado *jMIR*<sup>3</sup>. Trata-se de um conjunto de funcionalidades desenvolvidas em Java, cujo objetivo consiste na classificação automática de músicas (MCKAY; FUJINAGA, 2009). Além deste objetivo, o *jAudio* permite a análise de formatos como MP3, wav, aiff, aifc, au e snd. É possível salvar os resultados nos formatos ARFF (*Attribute-Relation File Format*) e ACE XML (MCKAY, 2010).

O *jAudio* possibilita a extração de 28 descritores, tais como os relacionados ao espectro do sinal (*spectral centroid*; *spectral rolloff*; *spectral flux*) e os relacionados ao domínio do tempo (*zero crossings*; *linear predictive coding*). Além disso, possui uma *interface* que permite a extração destes sem a necessidade de se escrever linhas de código.

Outras funcionalidades da ferramenta consistem na possibilidade de gravação do áudio diretamente do microfone do computador e na verificação de informações a respeito dos arquivos analisados (MCKAY, 2010).

Para este estudo, foram extraídos dois grupos de descritores: a) descritores obtidos no domínio do tempo; e b) descritores obtidos no domínio da frequência.

Os descritores obtidos no domínio do tempo são descritos a seguir.

### 3.2.1 Descritores obtidos no domínio do tempo

De acordo com McKay (2010) descritores temporais são aqueles obtidos, normalmente, a partir da sequência de amostras que representam o sinal digital. Dentre estes descritores, para este estudo, utilizaram-se os seguintes:

<sup>3</sup> Disponível em: <<http://jmir.sourceforge.net/>>. Acesso em: 12 jun. 2017.

- **Root Mean Square (RMS)**: representa a amplitude média quadrática de um sinal. É calculada a partir da Equação 4:

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N x[n]^2} \quad (4)$$

- **Taxa de Cruzamento Zero (Zero Crossings)**: informa quantas vezes o sinal cruza o eixo zero. Seu cálculo é realizado pela Equação 5:

$$Z_t = \frac{1}{2} \sum_{n=1}^N |\text{sign}(x[n]) - \text{sign}(x[n-1])| \quad (5)$$

- **Baixa Energia (Fraction of Low Energy Frames)**: obtida por meio da análise um conjunto de janelas consecutivas que têm um valor RMS abaixo de algum limite (MCKAY, 2010).

Os descritores relacionados ao domínio da frequência são descritos a seguir.

### 3.2.2 Descritores obtidos no domínio da frequência

Descritores obtidos no domínio da frequência são aqueles obtidos, geralmente, pela aplicação da Transformada Discreta de Fourier (DFT) (MCKAY, 2010).

Para este estudo, os seguintes descritores foram utilizados:

- **Centroide Espectral (Spectral Centroid)**: “é o ponto balanceado do espectro. É uma medida da forma espectral e é associado frequentemente com a noção do brilho espectral”. (SILLA JUNIOR; KAESTNER; KOERICH, 2005, p.51). É calculado pela Equação 6:

$$SC_t = \frac{\sum_{n=1}^N P_t[n] * n}{\sum_{n=1}^N P_t[n]} \quad (6)$$

- **Rolloff Espectral (Spectral Rolloff)**: medida espectral definida como a frequência SR - aqui representada na Equação x - na qual k da magnitude da distribuição está concentrada (SILLA JUNIOR; KAESTNER; KOERICH, 2005).

Para k, normalmente, adota-se 0,85 ou 0,95 (MCKAY, 2010). Este descritor é obtido por meio da Equação 7.

$$\sum_{n=1}^{SR_t} P_t[n] = k \sum_{n=1}^N P_t[n] \quad (7)$$

- **Fluxo Espectral (Spectral Flux)**: medida relacionada à mudança espectral de um sinal (MCKAY, 2010). É obtida pela Equação 8.

$$SF_t = \sum_{n=1}^N (N_t[n] - N_{t-1}[n])^2 \quad (8)$$

- **Coeficientes Cepstrais da frequência Mel - Mel-frequency cepstral coefficients (MFCC)**: “são características perceptualmente motivadas que também são baseadas na transformada de Fourier (*Short Time Fourier Transform* - STFT)” (SILLA JUNIOR; KAESTNER; KOERICH, 2005, p.51). Normalmente, de acordo com McKay (2010), são utilizados 13 coeficientes desta escala. Contudo, de acordo com Silla Junior, Kaestner e Koerich (2005), cinco coeficientes apresentam resultados melhores para a classificação de gêneros musicais.
- **Compactness**: descritor baseado no trabalho de McAdams (1999). Calculado a partir da Equação 9:

$$C = \sum_{n=2}^{N-1} \left( \log(M_t[n]) - \frac{\log(M_t[n-1]) + \log(M_t[n]) + \log(M_t[n+1]))}{3} \right) \quad (9)$$

Após a extração dos descritores, a próxima etapa consistiu na Mineração de Dados; etapa esta em que os dados foram submetidos à tarefa de classificação. As ferramentas para esta etapa são listadas na próxima seção.

### 3.2.3 Ferramentas de Mineração de Dados

Para a realização da Mineração de Dados - assim como a extração de descritores - foi necessário identificar quais ferramentas possibilitavam este procedimento. As ferramentas identificadas são listadas no Quadro 9.

QUADRO 9- FERRAMENTAS PARA MINERAÇÃO DE DADOS.

Nome	URL	Licença
<i>Weka</i>	<a href="http://www.cs.waikato.ac.nz/ml/weka/">http://www.cs.waikato.ac.nz/ml/weka/</a>	Gratuita
<i>MATLAB</i>	<a href="https://www.mathworks.com/products/matlab.html">https://www.mathworks.com/products/matlab.html</a>	Paga
<i>R</i>	<a href="https://cran.r-project.org/">https://cran.r-project.org/</a>	Gratuita
<i>Wolfram mathematica</i>	<a href="https://www.wolfram.com/mathematica/">https://www.wolfram.com/mathematica/</a>	Paga
<i>RapidMiner</i>	<a href="https://rapidminer.com/">https://rapidminer.com/</a>	Gratuita; Paga
<i>SAS</i>	<a href="https://www.sas.com/pt_br/home.html">https://www.sas.com/pt_br/home.html</a>	Paga
<i>SPSS</i>	<a href="https://www.ibm.com/analytics/us/en/technology/spss/">https://www.ibm.com/analytics/us/en/technology/spss/</a>	Paga
<i>Orange</i>	<a href="https://orange.biolab.si/">https://orange.biolab.si/</a>	Gratuita
<i>ELKI</i>	<a href="https://elki-project.github.io/">https://elki-project.github.io/</a>	Gratuita
<i>LIBSVM</i>	<a href="https://www.csie.ntu.edu.tw/~cjlin/libsvm/">https://www.csie.ntu.edu.tw/~cjlin/libsvm/</a>	Gratuita
<i>Mahout</i>	<a href="http://mahout.apache.org/">http://mahout.apache.org/</a>	Gratuita

FONTE: Adaptado de Castro e Ferrari (2016, p. 536-540)

A ferramenta escolhida para este estudo foi o Weka, por ser uma ferramenta gratuita e por possibilitar a leitura de arquivos no formato ARFF, um dos formatos gerados pelo *JAudio*. De acordo com Castro e Ferrari (2016), a ferramenta possui uma

*interface* gráfica, em que o usuário realiza tarefas de pré-processamento e visualização dos dados.

O Weka permite a realização das tarefas de classificação, regressão e agrupamento, além de possibilitar integração com ambientes de desenvolvimento Java, como o NetBeans e o Eclipse (CASTRO; FERRARI, 2016).

Para realizar as estatísticas descritivas referentes à base de dados, optou-se pela ferramenta SPSS, posto que, adquiriu-se conhecimentos a respeito da utilização da ferramenta graças ao uso desta em projetos de iniciação científica e extensão, além de disciplinas cursadas ao longo do curso. Além disso, trata-se de uma ferramenta disponível nos laboratórios do Setor de Ciências Sociais Aplicadas.

### 3.3 BASES DE DADOS

Nesta seção descreve-se os passos realizados para a construção das bases de dados utilizadas neste estudo. São elencados os passos de identificação das músicas, tratamento dos arquivos de áudio e o processo de extração dos descritores.

#### 3.3.1 Identificação das músicas

Para a construção das bases de dados, identificaram-se no dia 24 de junho de 2017, na rede social LastFM, as 150 principais músicas dos sete gêneros escolhidos neste estudo (*Heavy Metal; Jazz; Pop; Rock; Samba; MPB e Música Clássica*) totalizando 1050 músicas. A relação das músicas identificadas é listada no Apêndice A.

Após a identificação das músicas na rede social, a próxima etapa consistiu na coleta dessas na plataforma Youtube. A extração do áudio dos vídeos da plataforma foi realizada por meio do site *Online Video Converter*<sup>4</sup>, que permite converter um vídeo do Youtube para arquivos como .mp3, .wma, .flac e .wav (FIGURA 23).

---

<sup>4</sup> Disponível em: <<https://www.onlinevideoconverter.com/pt/mp3-converter>>. Acesso em 06 ago. 2017.

FIGURA 23- CONVERSOR ONLINE

FONTE: *Online Video Converter* (2017).

Para a conversação, os *links* de cada vídeo foram carregados no conversor e convertidos para o formato .mp3, com uma qualidade de 192 kbps, e respeitando a duração total de cada vídeo.

### 3.3.2 Tratamento dos arquivos

Após a coleta dos arquivos, utilizou-se a ferramenta *WavePad Sound Editor*<sup>5</sup> para transformá-los em arquivos .wav. Optou-se por trabalhar com este tipo de arquivo por duas razões: a) a ferramenta empregada para extração dos descritores, apesar de aceitar arquivos .mp3 não possibilitou o carregamento de todos os arquivos; e b) essa estratégia foi empregada em outros trabalhos semelhantes, tais como os realizados por Malheiro (2013) e Goulart (2012).

Com relação às características dos novos arquivos, adotou-se para todos uma frequência de 44100 Hz e uma taxa de *bits* de 1411 kbps. Após a conversão dos 1050 registros retirados do Youtube, adotou-se a estratégia de trabalhar com todos os arquivos com a mesma duração, para isso, recortaram-se 30 s de todos os arquivos; os 30 s consistiram do trigésimo segundo até o primeiro minuto de cada arquivo. Este procedimento foi realizado por meio da ferramenta Audacity<sup>6</sup>.

<sup>5</sup> Disponível em: <<http://www.nch.com.au/wavepad/index.html>>. Acesso em: 25 ago. 2017.

<sup>6</sup> Disponível em: <<http://www.audacityteam.org/download/>>. Acesso em: 25 ago. 2017.

Após os procedimentos relatados acima, adotou-se para este estudo duas bases; a primeira, com os 1050 arquivos com a duração original, a segunda, com os 1050 arquivos com 30 s de duração.

### 3.3.3 Extração dos descritores

A extração dos descritores foi realizada com o auxílio da ferramenta *jAudio*. Para esta etapa, carregaram-se na ferramenta cada um dos conjuntos de 150 registros de cada gênero, das duas bases utilizadas (2100 ao total).

A relação dos descritores extraídos da base com duração original é listada no Quadro 10.

QUADRO 10- RELAÇÃO DOS DESCRITORES EXTRAÍDOS DA BASE COM DURAÇÃO ORIGINAL.

<b>Descritor</b>	<b>Mínimo</b>	<b>Máximo</b>	<b>Média</b>	<b>Desvio Padrão</b>	<b>Tipo (atributo)</b>
<i>Spectral Centroid</i> (Desvio Padrão)	2,52	44800,00	14492,34	7311,96	Numérico
<i>Spectral Rolloff Point</i> (Desvio Padrão)	0,02	318,00	120,57	61,47	Numérico
<i>Spectral Flux</i> (Desvio Padrão)	0,00	14,20	2,18	2,372	Numérico
<i>Compactness</i> (Desvio Padrão)	128,00	867000,00	212051,49	109065,99	Numérico
<i>Root Mean Square</i> (Desvio Padrão)	0,00	161,00	54,45	32,28	Numérico
<i>Fraction Of Low Energy Windows</i> (Desvio Padrão)	0,02	267,00	59,88	31,88	Numérico
<i>Zero Crossings</i> (Desvio Padrão)	5,80	85600,00	29873,46	14824,84	Numérico
<i>MFCC 1</i> (Desvio Padrão)	17,20	530000,00	81089,81	69219,16	Numérico
<i>MFCC 2</i> (Desvio Padrão)	2,51	12200,00	4485,33	2051,50	Numérico
<i>MFCC 3</i> (Desvio Padrão)	2,05	6560,00	3279,22	1337,63	Numérico
<i>MFCC 4</i> (Desvio Padrão)	1,88	4680,00	2366,74	894,32	Numérico
<i>MFCC 5</i> (Desvio Padrão)	1,96	4560,00	2338,16	899,09	Numérico



<i>Spectral Centroid</i> (Média)	9,74	51000,00	21241,28	10372,95	Numérico
<i>Spectral Rolloff Point</i> (Média)	0,04	403,00	146,16	82,88	Numérico
<i>Spectral Flux</i> (Média)	0,00	11,40	1,75	1,89	Numérico
<i>Compactness</i> (Média)	1160,00	1920000,00	1457202,32	496598,48	Numérico
<i>Root Mean Square</i> (Média)	0,00	333,00	116,84	75,612	Numérico
<i>Fraction Of Low Energy Windows</i> (Média)	0,46	669,00	493,06	161,39	Numérico
<i>Zero Crossings</i> (Média)	24,00	123000,00	55876,25	26892,42	Numérico
<i>MFCC 1</i> (Média)	- 683000,00	-84,70	-115217,97	55244,28	Numérico
<i>MFCC 2</i> (Média)	-6000,00	27100,00	4642,90	5009,35	Numérico
<i>MFCC 3</i> (Média)	-5670,00	5590,00	418,79	1247,65	Numérico
<i>MFCC 4</i> (Média)	-10800,00	11200,00	1457,68	2507,17	Numérico
<i>MFCC 5</i> (Média)	-6050,00	3770,00	-137,76	1178,12	Numérico

FONTE: O Autor (2017).

Por sua vez, os descritores da base com duração de 30 s são listados no Quadro 11.

QUADRO 11- RELAÇÃO DOS DESCRITORES EXTRAÍDOS DA BASE COM DURAÇÃO DE 30 S.

<b>Descritor</b>	<b>Mínimo</b>	<b>Máximo</b>	<b>Média</b>	<b>Desvio Padrão</b>	<b>Tipo (atributo)</b>
<i>Spectral Centroid</i> (Desvio Padrão)	2,33	43600,00	13625,30	8103,65	Numérico
<i>Spectral Rolloff Point</i> (Desvio Padrão)	0,02	320,00	113,32	67,73	Numérico
<i>Spectral Flux</i> (Desvio Padrão)	0,00	15,40	2,10	2,50	Numérico
<i>Compactness</i> (Desvio Padrão)	124,00	3050	155727,19	59318,37	Numérico
<i>Root Mean Square</i> (Desvio Padrão)	0,00	142,00	43,81	29,42	Numérico
<i>Fraction Of Low Energy Windows</i> (Desvio Padrão)	0,02	146,00	44,37	23,06	Numérico

<i>Zero Crossings</i> (Desvio Padrão)	6,49	82600,00	28144,17	15529,76	Numérico
<i>MFCC 1</i> (Desvio Padrão)	4,08	51100,00	11847,33	6465,90	Numérico
<i>MFCC 2</i> (Desvio Padrão)	2,23	11800,00	3868,43	1895,47	Numérico
<i>MFCC 3</i> (Desvio Padrão)	1,41	8160,00	3168,96	1324,18	Numérico
<i>MFCC 4</i> (Desvio Padrão)	1,85	4710,00	2331,29	855,24	Numérico
<i>MFCC 5</i> (Desvio Padrão)	1,75	4500,00	2305,88	923,61	Numérico
<i>Spectral Centroid</i> (Média)	7,08	53800,00	20522,66	10433,50	Numérico
<i>Spectral Rolloff Point</i> (Média)	0,05	451,00	139,54	84,21	Numérico
<i>Spectral Flux</i> (Média)	0,00	9,37	1,67	1,96	Numérico
<i>Compactness</i> (Média)	1530,00	1930000,00	1492640,37	486220,73	Numérico
<i>Root Mean Square</i> (Média)	0,00	351,00	113,55	77,45	Numérico
<i>Fraction Of Low Energy Windows</i> (Média)	0,46	705,00	493,51	164,55	Numérico
<i>Zero Crossings</i> (Média)	24,00	135000,00	52960,45	28423,08	Numérico
<i>MFCC 1</i> (Média)	- 2040000,00	-76,70	-103990,41	39655,79	Numérico
<i>MFCC 2</i> (Média)	-15400,00	32400,00	5460,50	5655,81	Numérico
<i>MFCC 3</i> (Média)	-10200,00	12600,00	1691,58	2934,78	Numérico
<i>MFCC 4</i> (Média)	-5340,00	6890,00	444,21	1499,70	Numérico
<i>MFCC 5</i> (Média)	-6350,00	4530,00	-181,54	1557,79	Numérico

FONTE: O Autor (2017).

Todos os descritores foram extraídos mediante a utilização de uma janela de 512 amostras, sem sobreposição. De acordo com Malheiro (2013), a utilização de uma janela de 512 amostras em sinais com taxa de amostragem de 44100 Hz proporciona uma janela de análise de aproximadamente 11,6 ms, com uma resolução espectral de 86,13 Hz.

Após a obtenção dos 24 descritores, somou-se a estes o respectivo gênero de cada registro, dessa forma, para este estudo, formou-se um vetor com 25 características.

### 3.4 ALGORITMOS

Visando identificar quais algoritmos empregar neste estudo, realizaram-se testes com 23 algoritmos da ferramenta Weka nas bases de dados escolhidas, a fim de encontrar aqueles com as maiores capacidades de classificação.

Para todos os algoritmos utilizaram-se os valores *default* para os respectivos parâmetros e validação cruzada (*Cross-Validation*) igual a dez. Os resultados dos testes para a base de duração original são apresentados no Apêndice B.

Com base no Apêndice B, verifica-se que dos 23 algoritmos, apenas cinco (*Random Forest*; *Bagging (Random Forest)*; *AdaBoostM1 (Random Forest)*; *Bagging (Bayes Net)*; *Bayes Net*) obtiveram uma taxa de acerto superior a 50,00%.

Adotando os mesmos procedimentos da base de duração inteira, os resultados dos testes para a base de 30 s são apresentados no Apêndice C.

Com base no Apêndice C, verifica-se que dos 23 algoritmos, nenhum obteve uma taxa de acerto superior a 50,00%, contudo, nota-se que o *ranking* dos cinco melhores algoritmos não teve alteração.

Tendo em mãos o desempenho dos algoritmos, para este estudo, optou-se por empregar os cinco algoritmos com a melhor taxa de acerto, uma vez que, para ambas as bases, os resultados obtidos foram semelhantes.

Além disso, visando a comparação de resultados, definiu-se a aplicação dos algoritmos SVM e KNN haja vista a constante utilização destes em trabalhos de classificação de gêneros musicais.

Uma breve descrição de cada algoritmo é apresentada a seguir.

#### 3.4.1 *Random Forest*

O algoritmo *Random Forest* (RF) foi proposto por Breiman (2001) e caracteriza-se como um algoritmo de classificação e regressão. Sua principal característica consiste na construção de um conjunto de árvores de decisão.

A atribuição de uma classe a uma determinada instância ocorre pela submissão de cada instância às árvores de decisão geradas pelo algoritmo, que determinam uma classe cada; a classificação final consiste na classe que recebeu o maior número de votos (classe da maioria).

### 3.4.2 *Bayes Net*

O algoritmo *Bayes Net* é baseado no conceito das redes bayesianas (FRIEDMAN; GEIGER; GOLDSZMIDT, 1997). Uma rede bayesiana consiste em um conjunto de grafos acíclicos dirigidos que permitem uma representação eficiente e efetiva da distribuição de probabilidade condicional para determinado conjunto de variáveis aleatórias, dessa forma, cada vértice no grafo representa uma variável aleatória, e as bordas representam correlações diretas entre as variáveis.

### 3.4.3 *Support Vector Machine*

*Support Vector Machine* (SVM) consiste em um classificador binário embasado nos estudos desenvolvidos por Vapnik (2013), tais como a teoria da Aprendizagem Estatística e a teoria da Otimização.

O objetivo deste classificador recaí em classificar um conjunto de dados em diferentes categorias a partir de um hiperplano de separação. Apesar de ser inicialmente destinado à classificação binária, este algoritmo também é empregado em estudos de classificação com mais de duas classes.

### 3.4.4 *K- Nearest Neighbor*

O algoritmo *K-Nearest Neighbor* (KNN) é um dos métodos mais simples e antigos para a tarefa de classificação (COVER; HART, 1967). Esse método consiste em classificar uma instância com base no seu vizinho mais próximo.

Para isso, estabelece-se um valor para K - número de vizinhos a serem utilizados para a classificação da nova instância - e calcula-se uma distância - geralmente aplica-se a distância Euclidiana - dessa instância em relação aos demais dados do conjunto.

### 3.4.5 *Bagging e Boosting*

*Bagging* (BREIMAN, 1996) consiste em uma técnica que utiliza várias versões de um conjunto de treinamento. As versões são criadas a partir da seleção aleatória

de amostras desse conjunto, em que cada versão é utilizada para a criação classificadores. A classificação final ocorre após a combinação de todos esses classificadores, levando em consideração a classe mais votada.

*Boosting* (FREUND; SCHAPIRE, 1997) caracteriza-se como uma técnica iterativa capaz de melhorar a precisão de um classificador por meio da atribuição de pesos aos registros, penalizando os modelos com a menor precisão. Dentre os diferentes métodos de *boosting*, o algoritmo mais utilizado é o *AdaBoost* (FREUND; SCHAPIRE, 1999), algoritmo empregado neste estudo.

## 4 RESULTADOS

Nesta seção, apresenta-se os resultados obtidos após os experimentos realizados para as bases deste estudo.

### 4.1 RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL

Ao iniciar-se a etapa de Mineração de Dados, verificou-se que, apesar de os sete gêneros conterem a mesma quantidade de valores – 150 registros cada – os gêneros MPB e Samba apresentavam sempre uma taxa de acerto inferior aos demais gêneros, motivada pelo fato de que os algoritmos não conseguiam distinguir esses dois gêneros (conforme observado após análise das matrizes de confusão dos experimentos).

Desta forma, optou-se por realizar três tipos de análises: a) análise com os sete gêneros musicais (1050 registros); b) análise com cinco gêneros, sem a presença dos gêneros MPB e Samba (750 registros); e c) análise com apenas MPB e Samba (300 registros).

#### 4.1.1 Resultados para a base com duração original (*Random Forest*)

O primeiro experimento consistiu na aplicação do algoritmo *Random Forest*. Para este algoritmo, variou-se o parâmetro *l* (número de iterações), adotando-se valores de *l*=100 (*default*) a *l*=1000. Ressalta-se que, para valores superiores a 1000, os resultados obtidos não apresentaram mudanças.

Os resultados para este algoritmo são representados na Figura 24.

FIGURA 24- RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL (RANDOM FOREST)

Base Inteira (7 gêneros)			Base Inteira (5 gêneros)			Base Inteira (MPB x SAMBA)		
Parâmetros	Acertos (%)	ICC	Parâmetros	Acertos (%)	ICC	Parâmetros	Acertos (%)	ICC
Default (I (100))	52,10	547	Default (I (100))	64,13	481	RF (I (600))	56,00	168
I (200)	52,57	552	I (200)	64,27	482			
I (300)	52,30	549	I (300)	64,80	486			
I (400)	52,38	550	I (400)	65,07	488			
I (500)	52,30	549	I (500)	65,07	488			
I (600)	52,00	546	I (600)	65,60	492			
I (700)	52,38	550	I (700)	65,20	489			
I (800)	52,95	556	I (800)	65,20	489			
I (900)	52,67	553	I (900)	65,07	488			
I (1000)	52,57	552	I (1000)	65,33	490			

FONTE: O Autor (2017).

Observando-se a Figura 24 verifica-se que nos três cenários propostos a taxa de acerto foram superiores aos 50,00%. No caso das bases com sete e cinco gêneros, nota-se que base com cinco gêneros apresentou uma taxa superior à base com sete gêneros (65,60% a 52,95%). Com relação ao algoritmo, nota-se que para a base com sete gêneros o melhor foi obtido com o valor de parâmetro I=800; enquanto que para as bases com 5 e 2 gêneros o melhor resultado foi para I=600.

Com relação à matriz de confusão para os melhores cenários obtidos, apresentam-se estas na Figura 25.

FIGURA 25- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO ORIGINAL (RANDOM FOREST)

Matriz de Confusão (Base 7 gêneros)							
SAMBA	ROCK	POP	MPB	JAZZ	HM	MC	
54	7	18	43	20	2	6	SAMBA
5	66	16	14	11	34	4	ROCK
16	23	72	17	10	10	2	POP
43	11	13	46	31	2	4	MPB
17	10	11	16	82	2	12	JAZZ
2	30	3	5	6	104	0	HM
0	6	0	2	10	0	132	MC

Matriz de Confusão (Base 5 gêneros)				
ROCK	POP	JAZZ	HM	MC
72	22	17	35	4
25	90	23	9	3
11	23	101	3	12
34	5	10	101	0
7	0	15	0	128

Matriz de Confusão (MPB x SAMBA)		
SAMBA	MPB	
83	67	SAMBA
65	85	MPB

FONTE: O Autor (2017).

Analisando-se a Figura 25 nota-se que a baixa porcentagem de acerto para os gêneros MPB (30,60%) e Samba (36,00%) para a base com sete gêneros. Com relação à base com cinco gêneros, verifica-se que apenas o gênero Rock não obteve uma taxa de acerto acima dos 50,00% (48,00%). Quanto à base com MPB e Samba, percebe-se uma grande presença de valores classificados incorretamente: 67

registros de Samba classificados como MPB e 65 registros de MPB classificados como Samba.

#### 4.1.2 Resultados para a base com duração original (*Bayes Net*)

Para o algoritmo *Bayes Net* alternaram-se dois parâmetros: a) *estimator*; e b) *search Algorithm*. Os resultados obtidos para este algoritmo são listados no APÊNDICE D.

Observando-se APÊNDICE D, verifica-se que nos três cenários propostos, apenas para a base com sete gêneros a taxa de acerto foi inferior a 50,00%. No caso das bases com sete e cinco gêneros, nota-se que base com cinco gêneros apresentou uma taxa superior à base com sete gêneros (62,67 % a 48,19%). Com relação ao algoritmo, nota-se que para os três cenários a melhor combinação consistiu de: a) *estimator* = *Simple Estimator*; e b) *search Algorithm* = *TAN*.

Com relação à matriz de confusão para os melhores cenários obtidos, apresentam-se estas na Figura 26.

FIGURA 26- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO ORIGINAL (BAYES NET)

Matriz de Confusão (Base 7 gêneros)							
SAMBA	ROCK	POP	MPB	JAZZ	HM	MC	
46	13	23	38	25	3	2	SAMBA
12	56	23	17	7	33	2	ROCK
19	21	62	20	14	12	2	POP
42	15	12	45	32	3	1	MPB
19	5	13	25	72	6	10	JAZZ
4	27	9	8	5	97	0	HM
4	3	2	4	9	0	128	MC

Matriz de Confusão (Base 5 gêneros)					
ROCK	POP	JAZZ	HM	MC	
65	22	22	40	1	ROCK
23	80	27	19	1	POP
12	26	98	6	8	JAZZ
36	8	8	98	0	HM
3	6	11	1	129	MC

Matriz de Confusão (MPB x SAMBA)		
SAMBA	MPB	
108	42	SAMBA
69	81	MPB

FONTE: O autor (2017).

Analisando-se a Figura 26 nota-se que há uma baixa porcentagem de acerto para os gêneros MPB (30,00%) e Samba (36,00%) para a base com sete gêneros. Com relação à base com cinco gêneros, verifica-se que apenas o gênero Rock não obteve uma taxa de acerto acima dos 50,00% (43,30%). Quanto à base com MPB e Samba, os dois gêneros apresentaram uma taxa de acerto superior a 50,00%: Samba (72,00%) e MPB (54,00%).



#### 4.1.3 Resultados para a base com duração original (KNN)

Para o algoritmo KNN o único parâmetro alterado consistiu para o valor de K, que consiste no número de vizinhos utilizados para a classificação. Para os valores do parâmetro K, ressalta-se que acima de 15 vizinhos a taxa de acerto estabilizou-se.

Os resultados obtidos para este algoritmo são listados no APÊNDICE E.

Observando-se o APÊNDICE E, verifica-se que para a base com sete gêneros a taxa de acerto foi a única abaixo dos 50,00% (39,43%) - o método teve mais erros do que acertos -, entretanto, o desempenho do algoritmo foi superior para a base com cinco gêneros (53,47%) e para a classificação dos gêneros MPB e Samba (52,33%).

Com relação aos valores para o parâmetro K, houve diferenças para as bases: para a base com sete gêneros, o melhor desempenho foi obtido para K=15, por sua vez, o valor de K=9 foi o melhor para as bases com cinco e dois gêneros.

Com relação à matriz de confusão para os melhores cenários obtidos, apresentam-se estas na Figura 27.

FIGURA 27- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO ORIGINAL (KNN)

Matriz de Confusão (Base 7 gêneros)							
SAMBA	ROCK	POP	MPB	JAZZ	HM	MC	
49	15	17	33	25	3	8	SAMBA
22	58	10	17	13	28	2	ROCK
26	39	43	14	10	15	3	POP
41	26	15	28	32	2	6	MPB
34	15	11	25	50	2	13	JAZZ
10	48	6	9	6	70	1	HM
7	5	0	2	20	0	116	MC

Matriz de Confusão (Base 5 gêneros)					
ROCK	POP	JAZZ	HM	MC	
78	11	25	28	8	ROCK
60	52	21	11	6	POP
26	17	80	10	17	JAZZ
58	7	12	72	1	HM
11	2	18	0	119	MC

Matriz de Confusão (MPB x SAMBA)		
SAMBA	MPB	
84	66	SAMBA
77	73	MPB

FONTE: O autor (2017).

Observando-se a Figura 27 nota-se que, para a base com sete gêneros, apenas a Música Clássica (MC) obteve taxa de acerto acima de 50,00% (77,33%). Em contrapartida, a base de cinco gêneros apresentou três gêneros com taxas superiores aos 50,00%: Rock (52,00%); Jazz (53,33%); e MC (79,33%).

Com relação à base com MPB e Samba, o algoritmo KNN não apresentou taxas consistentes de classificação, obtendo valores próximos de instâncias

classificadas corretamente e instâncias incorretas, sendo: 56,00% de acerto para o gênero Samba e 48,70% para o gênero MPB.

#### 4.1.4 Resultados para a base com duração original (SVM)

Para o algoritmo SVM, três parâmetros foram alterados: a) o tipo do classificador SVM (C-SVC; nu-SVC); b) o tipo do *kernel* (Linear; Polynomial; *Radial Basis Function* (RBF); Sigmoid); e c) o valor para o parâmetro de custo (C). Para este algoritmo, utilizou-se, ainda, a opção de trabalhar com os dados normalizados.

Os resultados obtidos para este algoritmo são listados no APÊNDICE F.

Analisando-se os resultados obtidos para os experimentos envolvendo o algoritmo SVM (APÊNDICE F), nota-se que o melhor resultado para a base de sete gêneros consistiu na combinação do SVM *nu-SVM* com o *kernel RBF* e assumindo o valor de “1” para o parâmetro C; o resultado desta combinação foi uma taxa de acerto de 44,48%.

Por sua vez, para a base de cinco e dois gêneros, o melhor resultado apresentou taxa de acerto de 54,00% para esta, e 59,07% para essa. Ambos os resultados foram obtidos mediante a combinação do SVM *nu-SVM* com o *kernel linear* e “0,5” para o valor de C.

Com relação à matriz de confusão para os melhores cenários obtidos, apresentam-se estas na Figura 28.

FIGURA 28- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO ORIGINAL (SVM)

Matriz de Confusão (Base 7 gêneros)							
SAMBA	ROCK	POP	MPB	JAZZ	HM	MC	
36	12	21	43	25	2	11	SAMBA
11	59	15	16	12	31	6	ROCK
15	20	61	17	18	15	4	POP
37	16	14	41	28	4	10	MPB
28	11	13	21	58	3	16	JAZZ
7	40	5	5	10	83	0	HM
3	3	2	3	10	0	129	MC

Matriz de Confusão (Base 5 gêneros)					
ROCK	POP	JAZZ	HM	MC	
59	23	31	31	6	ROCK
22	80	28	14	6	POP
20	24	81	5	20	JAZZ
36	9	13	92	0	HM
1	2	16	0	131	MC

Matriz de Confusão (MPB x SAMBA)		
SAMBA	MPB	
85	65	SAMBA
73	77	MPB

FONTE: O Autor (2017).

Com base na Figura 28 percebe-se que, para a base com sete gêneros, apenas os gêneros MC e *Heavy Metal* (HM) obtiveram uma taxa de acertos acima dos 50,00%, sendo 86,00% para MC e 55,33% para HM. Para a base com cinco gêneros, destaca-se que o algoritmo melhorou seu desempenho de classificação para os gêneros POP (53,33%) e Jazz (54,00%), deixando apenas o gênero *Rock* (39,33%) abaixo dos 50,00% de acerto.

Quanto à base de composta apenas por MPB e Samba, o SVM apresentou dificuldades em distinguir os gêneros, uma vez que, os valores de instâncias corretas e incorretas foram próximos, sendo: 85 instâncias classificadas corretamente para o gênero Samba (56,67%) e 65 instâncias classificadas incorretamente (43,33%); por sua vez, para o gênero MPB, foram 77 instâncias classificadas corretamente (51,33%) e 73 instâncias classificadas incorretamente (48,67%).

#### 4.1.5 Resultados para a base com duração original (*Bagging*)

Para este tipo de classificação empregou-se o classificador *Bagging* mediante combinação deste com os algoritmos – e seus parâmetros – utilizados neste estudo, utilizando-se apenas o melhor cenário de cada algoritmo.

Os resultados obtidos para este algoritmo são listados no APÊNDICE G.

Analisando-se os resultados obtidos para os experimentos para este classificador (APÊNDICE G), percebe-se que o melhor resultado para a base de sete gêneros consistiu na combinação do *Bagging* com classificador *Random Forest*, com um valor de 800 para o parâmetro “I”. A taxa de acerto (52,10%) foi inferior ao valor obtido para o algoritmo sem o emprego do *Bagging* (52,95%), demonstrando que ao empregar o *Bagging* teve-se uma queda de desempenho para o algoritmo *Random Forest*.

Por sua vez, para a base de cinco gêneros, o melhor resultado apresentou taxa de acerto de 66,53% (499 instâncias classificadas corretamente) para o algoritmo *Bayes Net*; valor superior ao obtido para a utilização do algoritmo sozinho na mesma base (62,67%).

Referente à base composta por dois gêneros, o algoritmo *Bagging* não foi capaz de melhorar a taxa de acerto obtida para o algoritmo *Bayes Net*, uma vez que, obteve uma taxa de acerto de 61,67% contra 63,00% do algoritmo *Bayes Net* aplicado sem a técnica.

Com relação à matriz de confusão para os melhores cenários obtidos, apresentam-se estas na Figura 29.

FIGURA 29- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO ORIGINAL (BAGGING)

Matriz de Confusão (Base 7 gêneros)							
SAMBA	ROCK	POP	MPB	JAZZ	HM	MC	
50	8	17	42	25	1	8	SAMBA
6	59	18	15	12	36	4	ROCK
14	20	77	13	13	9	4	POP
41	12	12	46	33	2	4	MPB
13	8	13	18	82	4	12	JAZZ
2	29	4	5	5	105	0	HM
0	7	0	2	13	0	128	MC

Matriz de Confusão (Base 5 gêneros)					
ROCK	POP	JAZZ	HM	MC	
70	28	14	36	2	ROCK
21	92	22	12	3	POP
12	22	102	5	9	JAZZ
34	6	7	103	0	HM
3	2	13	0	132	MC

Matriz de Confusão (MPB x SAMBA)		
SAMBA	MPB	
94	56	SAMBA
59	91	MPB

FONTE: O autor (2017).

Analisando-se a Figura 29, nota-se que a base com sete gêneros apresentou três gêneros com porcentagem de acertos abaixo dos 50,00%, sendo: 33,33% para o gênero Samba; 39,33% para o gênero Rock; e 30,67% para o gênero MPB.

Quanto à base formada por cinco gêneros, apenas o gênero Rock ficou abaixo de 50,00% de acerto (46,67%), contudo, os demais gêneros atingiram taxas superiores a 60,00% de acerto.

No que tange à comparação de Samba e MPB, o emprego do *Bagging* possibilitou uma taxa de acerto superior a 60,00% para ambos os gêneros.

#### 4.1.6 Resultados para a base com duração original (*Boosting*)

Neste cenário aplicou-se o algoritmo *AdaBoost* mediante combinação deste com os algoritmos – e seus parâmetros – utilizados neste estudo, utilizando-se apenas o melhor cenário de cada algoritmo.

Os resultados obtidos para este algoritmo são listados no APÊNDICE H.

Analisando-se os resultados obtidos para os experimentos para este classificador (APÊNDICE H), percebe-se que o melhor resultado para a base de sete gêneros consistiu na combinação do algoritmo *AdaBoost* com classificador *Random Forest*, com um valor de 800 para o parâmetro “l”. A taxa de acerto (50,76%) foi inferior ao valor obtido para o algoritmo sem o emprego do *Boosting* (52,95%), demonstrando que a combinação proposta apresentou queda no desempenho para o algoritmo *Random Forest*.

Por sua vez, para a base de cinco gêneros, o melhor resultado apresentou taxa de acerto de 64,93% (487 instâncias classificadas corretamente) para o algoritmo *Random Forest*, com um valor de 600 para o parâmetro “l”; valor inferior ao obtido para a utilização do algoritmo sozinho na mesma base (65,60%).

Referente à base composta por dois gêneros, o algoritmo *Bagging* não foi capaz de melhorar a taxa de acerto obtida para o algoritmo *Bayes Net*, uma vez que, obteve uma taxa de acerto de 62,67% contra 63,00% do algoritmo *Bayes Net* aplicado sem a técnica.

Com relação à matriz de confusão para os melhores cenários obtidos, apresentam-se estas na Figura 30.

FIGURA 30- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO ORIGINAL (BOOSTING)

Matriz de Confusão (Base 7 gêneros)							
SAMBA	ROCK	POP	MPB	JAZZ	HM	MC	
50	7	14	50	22	2	5	SAMBA
3	59	16	18	11	36	7	ROCK
12	24	70	19	12	9	4	POP
44	12	12	46	31	2	3	MPB
17	7	10	29	73	3	11	JAZZ
3	27	2	7	5	106	0	HM
0	7	0	2	11	1	129	MC

Matriz de Confusão (Base 5 gêneros)					
ROCK	POP	JAZZ	HM	MC	
70	22	17	37	4	ROCK
30	86	22	10	2	POP
12	23	100	3	12	JAZZ
35	4	10	101	0	HM
6	0	14	0	130	MC

Matriz de Confusão (MPB x SAMBA)		
SAMBA	MPB	
106	44	SAMBA
68	82	MPB

FONTE: O autor (2017).

Analisando-se a Figura 30, nota-se que a base com sete gêneros apresentou dois gêneros com porcentagem de acerto acima dos 50,00%, sendo: 86,00% para o gênero MC e 70,67% para o gênero HM.

Quanto à base formada por cinco gêneros, apenas o gênero *Rock* ficou abaixo de 50,00% de acerto (46,67%), contudo, os demais gêneros atingiram taxas superiores a 55,00% de acerto.

No que tange à comparação de Samba e MPB, o emprego do *Boosting* possibilitou uma taxa de acerto superior a 50,00% para ambos os gêneros.

## 4.2 RESULTADOS PARA A BASE COM DURAÇÃO DE 30 s

Os experimentos para a base com duração de 30 s foram os mesmos descritos e aplicados para a base com duração original.

### 4.2.1 Resultados para a base com duração de 30 s (*Random Forest*)

Ao empregar-se o algoritmo *Random Forest*, variou-se o parâmetro *I* (número de iterações), adotando-se valores de *I*=100 (*default*) a *I*=1000. Os resultados para este algoritmo são representados na Figura 31.

Figura 31- RESULTADOS PARA A BASE COM DURAÇÃO DE 30 S (RANDOM FOREST)

Default (I (100))	47,53	499	Default (I (100))	64,13	481	RF (I (600))	56,33	169
I (200)	47,90	503	I (200)	64,27	482			
I (300)	48,10	505	I (300)	64,80	486			
I (400)	49,05	515	I (400)	65,07	488			
I (500)	48,38	508	I (500)	65,07	488			
I (600)	48,20	506	I (600)	65,60	492			
I (700)	48,10	505	I (700)	65,20	489			
I (800)	47,52	499	I (800)	65,20	489			
I (900)	47,62	500	I (900)	65,07	488			
I (1000)	47,52	499	I (1000)	65,33	490			

FONTE: O Autor (2017).

Observando-se a Figura 31 verifica-se que dos três cenários propostos, apenas a base com sete gêneros não apresentou taxa de acerto superior a 50,00% (49,05%). No caso das bases com sete e cinco gêneros, nota-se que base com cinco gêneros apresentou uma taxa superior à base com sete gêneros (65,60% a 49,07%).

Quanto ao algoritmo, nota-se que para a base com sete gêneros o melhor foi obtido com o valor de parâmetro *I*=400; enquanto que para as bases com cinco e dois gêneros o melhor resultado foi para *I*=600.

Com relação à matriz de confusão para os melhores cenários obtidos, apresentam-se estas na Figura 32.

FIGURA 32- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO DE 30 S (RANDOM FOREST)

Matriz de Confusão (Base 7 gêneros)							
SAMBA	ROCK	POP	MPB	JAZZ	HM	MC	
49	12	17	44	23	2	3	SAMBA
11	53	20	11	11	31	13	ROCK
22	14	70	18	13	10	3	POP
44	11	13	53	24	2	3	MPB
20	12	10	20	69	4	15	JAZZ
3	27	10	7	7	90	6	HM
2	4	0	1	12	0	131	MC

Matriz de Confusão (Base 5 gêneros)					
ROCK	POP	JAZZ	HM	MC	
61	29	19	30	11	ROCK
22	94	22	9	3	POP
17	18	98	2	15	JAZZ
33	11	13	86	7	HM
6	0	13	1	130	MC

Matriz de Confusão (MPB x SAMBA)		
SAMBA	MPB	
85	65	SAMBA
66	84	MPB

FONTE: O Autor (2017)

Analisando-se a Figura 32 nota-se que apenas os gêneros MC (87,33%) e HM (60,00%) apresentaram taxa de acerto superior a 50,00% de acerto para a base com sete gêneros. Com relação à base com cinco gêneros, verifica-se que apenas o gênero Rock não obteve uma taxa de acerto acima dos 50,00% (40,67%).

Quanto à base com MPB e Samba, percebe-se que o método apresentou valores próximos para as instâncias classificadas corretamente: Samba (85); MPB (84).

#### 4.2.2 Resultados para a base com duração de 30 s (*Bayes Net*)

Para o algoritmo *Bayes Net* alternaram-se dois parâmetros: a) *estimator*; e b) *search Algorithm*. Os resultados obtidos para este algoritmo são listados no APÊNDICE I.

Observando-se o APÊNDICE I verifica-se que nos três cenários propostos, apenas para a base com sete gêneros a taxa de acerto foi inferior a 50,00%. No caso das bases com sete e cinco gêneros, nota-se que base com cinco gêneros apresentou uma taxa superior à base com sete gêneros (62,67 % a 45,43%). Neste cenário, a base comparando Samba e MPB também alcançou desempenho superior à base com todos os gêneros: 60,67% a 45,43%.

No que tange ao algoritmo, nota-se que para os três cenários a melhor combinação consistiu de: a) *estimator* = *Simple Estimator*; e b) *search Algorithm* = *TAN*.

Com relação à matriz de confusão para os melhores cenários obtidos, apresentam-se estas na Figura 33.

FIGURA 33- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO DE 30 S (BAYES NET)

Matriz de Confusão (Base 7 gêneros)							
SAMBA	ROCK	POP	MPB	JAZZ	HM	MC	
54	12	20	28	30	3	3	SAMBA
14	42	20	16	15	32	11	ROCK
23	20	64	19	11	11	2	POP
36	19	18	43	28	3	3	MPB
21	13	14	24	62	3	13	JAZZ
7	27	5	12	6	88	5	HM
0	9	0	5	10	2	124	MC

Matriz de Confusão (Base 5 gêneros)					
ROCK	POP	JAZZ	HM	MC	
54	31	20	34	11	ROCK
28	84	20	34	2	POP
19	19	90	7	15	JAZZ
34	14	9	88	5	HM
10	1	8	1	130	MC

Matriz de Confusão (MPB x SAMBA)		
SAMBA	MPB	
96	54	SAMBA
69	86	MPB

FONTE: O Autor (2017).

Analisando-se a Figura 33 destaca-se - para a base com sete gêneros - a porcentagem de acerto para os gêneros MC (82,67%) e HM (58,67%) por serem os únicos a superarem os 50,00% de acerto. Quanto à classificação com cinco gêneros, destes apenas o gênero *Rock* (36,00%) não ultrapassou os 50,00% de acerto.

Quanto à base com MPB e Samba, a taxa de acerto para cada gênero superou o valor dos 50,00%, sendo: 64,00% para o gênero Samba e 57,33% para a MPB.

#### 4.2.3 Resultados para a base com duração de 30 s (KNN)

Para o algoritmo KNN o único parâmetro alterado consistiu para o valor de K, que consiste no número de vizinhos utilizados para a classificação.

Os resultados obtidos para este algoritmo são listados no APÊNDICE J.

Observando-se a APÊNDICE J verifica-se que para a base com sete gêneros a taxa de acerto foi a única abaixo dos 50,00% (38,48%) - o método teve mais erros do que acertos -, entretanto, o desempenho do algoritmo foi superior para a base com cinco gêneros (51,60%) e para a classificação dos gêneros MPB e Samba (57,33%).

Com relação aos valores para o parâmetro K, houve diferenças para as bases: para a base com sete gêneros, o melhor desempenho foi obtido para K=15, por sua vez, o valor de K=13 foi o melhor para as bases com cinco e dois gêneros.



Com relação à matriz de confusão para os melhores cenários obtidos, apresentam-se estas na Figura 34.

FIGURA 34- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO DE 30 S (KNN)

Matriz de Confusão (Base 7 gêneros)							
SAMBA	ROCK	POP	MPB	JAZZ	HM	MC	
69	13	14	20	17	11	6	SAMBA
31	45	11	17	6	26	14	ROCK
44	25	41	14	10	13	3	POP
60	15	11	34	20	6	4	MPB
52	15	9	19	34	6	15	JAZZ
18	40	10	7	4	61	10	HM
7	8	0	3	7	5	120	MC

Matriz de Confusão (Base 5 gêneros)					
ROCK	POP	JAZZ	HM	MC	
67	24	15	30	14	ROCK
44	65	18	20	3	POP
33	19	70	8	20	JAZZ
57	16	7	61	9	HM
11	2	8	5	124	MC

Matriz de Confusão (MPB x SAMBA)		
SAMBA	MPB	
104	46	SAMBA
82	68	MPB

FONTE: O Autor (2017).

Observando-se a Figura 34 nota-se que, para a base com sete gêneros, apenas a Música Clássica (MC) obteve taxa de acerto acima de 50,00% (80,00%). O mesmo cenário repetiu-se para a base de cinco gêneros: MC (82,67%).

Com relação à base com MPB e Samba, o algoritmo KNN apresentou um valor de 69,33% de acerto para o gênero Samba e 45,33% para a MPB.

#### 4.2.4 Resultados para a base com duração de 30 s (SVM)

Para o algoritmo SVM, três parâmetros foram alterados: a) o tipo do classificador SVM (C-SVC; nu-SVC); b) o tipo do *kernel* (Linear; Polynomial; *Radial Basis Function* (RBF); Sigmoid); e c) o valor para o parâmetro de custo (C). Para este algoritmo, utilizou-se, ainda, a opção de trabalhar com os dados normalizados.

Os resultados obtidos para este algoritmo são listados no APÊNDICE K.

Analisando-se os resultados obtidos para os experimentos envolvendo o algoritmo SVM (APÊNDICE K), nota-se que o melhor resultado para a base de sete gêneros consistiu na combinação do SVM C-SVC com o *kernel Linear* e assumindo o valor de “1” para o parâmetro C; o resultado desta combinação foi uma taxa de acerto de 44,95%.

Por sua vez, para a base de cinco e dois gêneros, o melhor resultado apresentou taxa de acerto de 60,13% para esta, e 55,33% para essa. Ambos os

resultados foram obtidos mediante a combinação do SVM C-SVC com o *kernel Linear* e assumindo o valor de “1” para o parâmetro C.

Com relação à matriz de confusão para os melhores cenários obtidos, apresentam-se estas na Figura 35.

FIGURA 35- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO DE 30 S (SVM)

Matriz de Confusão (Base 7 gêneros)							
SAMBA	ROCK	POP	MPB	JAZZ	HM	MC	
40	4	21	42	28	10	5	SAMBA
9	53	15	15	14	34	10	ROCK
23	20	63	17	17	6	4	POP
36	13	12	48	30	6	5	MPB
14	13	7	23	67	9	17	JAZZ
15	34	2	5	9	75	10	HM
2	4	1	2	11	4	126	MC

Matriz de Confusão (Base 5 gêneros)					
ROCK	POP	JAZZ	HM	MC	
57	23	22	38	10	ROCK
21	90	26	7	6	POP
14	13	92	14	17	JAZZ
34	7	15	86	8	HM
5	1	14	4	126	MC

Matriz de Confusão (MPB x SAMBA)		
SAMBA	MPB	
88	62	SAMBA
72	78	MPB

FONTE: O Autor (2017).

Com base na Figura 35 percebe-se que, para a base com sete gêneros, apenas o gênero MC (84,00%) ultrapassou o valor de 50,00% de acerto, e o gênero HM atingiu exatamente este valor (75 instâncias classificadas corretamente).

Para a base com cinco gêneros, destaca-se que o algoritmo melhorou seu desempenho de classificação, fazendo deixando apenas o gênero *Rock* (38,00%) abaixo dos 50,00% de acerto.

Quanto à base de composta apenas por MPB e Samba, o SVM apresentou dificuldades em distinguir os gêneros, uma vez que, os valores de instâncias corretas e incorretas foram próximos, sendo: 88 instâncias classificadas corretamente para o gênero Samba (58,67%) e 62 instâncias classificadas incorretamente (41,33%); por sua vez, para o gênero MPB, foram 78 instâncias classificadas corretamente (52,00%) e 72 instâncias classificadas incorretamente (48,00%).

#### 4.2.5 Resultados para a base com duração de 30 s (*Bagging*)

Para este tipo de classificação empregou-se o classificador *Bagging* mediante combinação deste com os algoritmos – e seus parâmetros – utilizados neste estudo, utilizando-se apenas o melhor cenário de cada algoritmo.

Os resultados obtidos para este algoritmo são listados no APÊNDICE L.

Analisando-se os resultados obtidos para os experimentos para este classificador (APÊNDICE L), percebe-se que o melhor resultado para a base de sete gêneros consistiu na combinação do *Bagging* com o classificador *Bayes Net*. A taxa de acerto (50,86%) foi superior ao valor obtido para o algoritmo sem o emprego do *Bagging* (45,43%), demonstrando que ao empregar o *Bagging* teve-se um aumento de desempenho para o algoritmo *Bayes Net*.

Por sua vez, para a base de cinco gêneros, o melhor resultado apresentou taxa de acerto de 62,40% (468 instâncias classificadas corretamente) para o algoritmo *Bayes Net*; valor inferior ao obtido para a utilização do algoritmo sozinho na mesma base (62,67%).

Referente à base composta por dois gêneros, o algoritmo *Bagging* apresentou desempenho superior para o algoritmo *Bayes Net* aplicado sem a técnica na mesma base: 61,67% a 60,67% de acerto.

Com relação à matriz de confusão para os melhores cenários obtidos, apresentam-se estas na Figura 36.

FIGURA 36- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO DE 30 S (BAGGING)

Matriz de Confusão (Base 7 gêneros)							
SAMBA	ROCK	POP	MPB	JAZZ	HM	MC	
59	15	17	33	21	5	0	SAMBA
11	52	23	13	12	31	8	ROCK
18	22	71	21	10	6	2	POP
35	16	18	52	25	2	2	MPB
15	9	14	21	75	4	12	JAZZ
3	34	6	5	5	92	5	HM
0	1	2	2	9	3	133	MC

Matriz de Confusão (Base 5 gêneros)					
ROCK	POP	JAZZ	HM	MC	
55	33	21	33	8	ROCK
23	94	21	9	3	POP
14	20	96	5	15	JAZZ
32	8	11	93	6	HM
10	0	10	0	130	MC

Matriz de Confusão (MPB x SAMBA)		
SAMBA	MPB	
89	61	SAMBA
54	96	MPB

FONTE: O Autor (2017).

Analisando-se a Figura 36, nota-se que a base com sete gênero apresentou quatro gêneros com porcentagem de acerto abaixo dos 50,00%, sendo: 40,45% para o gênero Samba; 34,67% para o gênero Rock; 47,33% para o gênero POP; e 34,67% para o gênero MPB.

Quanto à base formada por cinco gêneros, apenas o gênero Rock ficou abaixo de 50,00% de acerto (36,67%), contudo, os demais gêneros atingiram taxas superiores a 60% de acerto.

No que tange à comparação de Samba e MPB, o emprego do *Bagging* possibilitou uma taxa de acerto superior a 55% para ambos os gêneros.

#### 4.2.6 Resultados para a base com duração de 30 s (*Boosting*)

Neste cenário aplicou-se o algoritmo *AdaBoost* mediante combinação deste com os algoritmos – e seus parâmetros – utilizados neste estudo, utilizando-se apenas o melhor cenário de cada algoritmo.

Os resultados obtidos para este algoritmo são listados no APÊNDICE M.

Analisando-se os resultados obtidos para os experimentos para este classificador (APÊNDICE M), percebe-se que o melhor resultado para a base de sete gêneros consistiu na combinação do algoritmo *AdaBoost* com o classificador *Bayes Net*. A taxa de acerto (45,43%) foi a mesma para o algoritmo sem o emprego do *Boosting* (45,43%), demonstrando que a combinação proposta não teve efeito no desempenho para o algoritmo *Bayes Net*.

Por sua vez, para a base de cinco gêneros, o melhor resultado apresentou taxa de acerto de 62,00% (465 instâncias classificadas corretamente) para o algoritmo *Random Forest*, com um valor de 600 para o parâmetro “l”; valor inferior ao obtido para a utilização do algoritmo sozinho na mesma base (62,53%).

Referente à base composta por dois gêneros, o algoritmo *Bagging* não foi capaz de melhorar a taxa de acerto obtida para o algoritmo *Bayes Net*, uma vez que, obteve uma taxa de acerto de 60,67% contra 62,00% do algoritmo *Bayes Net* aplicado sem a técnica.

Com relação à matriz de confusão para os melhores cenários obtidos, apresentam-se estas na Figura 37.

FIGURA 37- MATRIZ DE CONFUSÃO PARA A BASE COM DURAÇÃO DE 30 S (BOOSTING)

Matriz de Confusão (Base 7 gêneros)							
SAMBA	ROCK	POP	MPB	JAZZ	HM	MC	
52	11	19	41	22	3	2	SAMBA
11	48	16	16	9	37	13	ROCK
20	13	71	19	14	10	3	POP
49	9	10	51	28	1	2	MPB
25	10	11	20	62	3	19	JAZZ
6	29	10	7	5	87	6	HM
2	4	0	1	12	0	131	MC

Matriz de Confusão (Base 5 gêneros)					
ROCK	POP	JAZZ	HM	MC	
61	30	20	28	11	ROCK
22	92	23	10	3	POP
18	18	94	3	17	JAZZ
33	10	12	88	7	HM
6	0	12	2	130	MC

Matriz de Confusão (MPB x SAMBA)		
SAMBA	MPB	
106	44	SAMBA
68	82	MPB

FONTE: O Autor (2017).

Analisando-se a Figura 37, nota-se que a base com sete gêneros apresentou dois gêneros com porcentagem de acerto acima dos 50,00%, sendo: 87,33% para o gênero MC e 58,00% para o gênero HM.

Quanto à base formada por cinco gêneros, apenas o gênero *Rock* ficou abaixo de 50,00% de acerto (40,67%), contudo, os demais gêneros atingiram taxas superiores a 55% de acerto.

No que tange à comparação de Samba e MPB, o emprego do *Boosting* possibilitou uma taxa de acerto superior a 50,00% para ambos os gêneros.

#### 4.3 COMPARAÇÃO DOS RESULTADOS

Com base nos resultados obtidos, verificou-se que ao retirar os gêneros MPB e Samba, todos os algoritmos apresentaram uma taxa de acerto superior a 50,00%. Ao utilizar-se a base com cinco gêneros, obteve-se a maior porcentagem de acerto - 66,53% - 499 instâncias classificadas corretamente – para um algoritmo, obtida por meio da combinação do algoritmo *Bayes Net* com a técnica de *Bagging*.

Com relação à classificação considerando-se apenas os gêneros MPB e Samba, os melhores cenários para cada algoritmo apresentaram resultados superiores à classificação utilizando os sete gêneros, com taxa de acerto acima dos 50,00%.

Com base no desempenho da classificação com dois gêneros apenas, justifica-se a opção em realizar a classificação destes dois gêneros sem a presença dos demais, posto que, a taxa de acerto foi superior à classificação realizada com todos

os gêneros musicais e, além disso, a classificação sem estes dois gêneros apresentou também os melhores resultados deste estudo.

Quanto à duração dos arquivos de áudio, observou-se que a base com arquivos com 30 s de duração apresentou um desempenho inferior à base com os arquivos com duração original - 48,00% a 46,03% com sete gêneros; 62,04% a 59,62% com cinco gêneros; 58,28% a 58,17% com dois gêneros -, demonstrando que para a tarefa de classificação a duração interfere no resultado final.

No que tange aos gêneros musicais, a música clássica em todos os experimentos demonstrou os melhores índices de acerto, com valores acima dos 80,00%. Destacam-se, ainda, os gêneros *Jazz* e *Heavy Metal*, com resultados superiores a 50,00% de acerto. Em contrapartida, gêneros como *Rock* e *Pop* não apresentaram um padrão nos resultados, variando conforme o método aplicado.

Quanto aos algoritmos empregados, destaca-se a combinação da técnica *Bagging* com o classificador *Bayes Net*, pois, dos seis cenários propostos, apresentou o melhor resultado em três destes, inclusive apresentando o melhor resultado geral (66,53% de acerto).

A comparação dos melhores cenários obtidos é representada no APÊNDICE N.

## 5 CONSIDERAÇÕES FINAIS

Após os resultados obtidos neste estudo, conclui-se que a classificação de gêneros musicais consiste em uma tarefa desafiadora para o Gestor da Informação, pois é necessário empregar e compreender uma gama de conhecimentos específicos obtidos em áreas como a Engenharia e a Computação que não fazem parte do dia a dia daquele profissional.

A classificação de gêneros musicais apresentou-se como um “problema interessante” para trabalhos que envolvem técnicas de Aprendizagem de Máquina (*Machine Learning*), uma vez que, existem gêneros formados a partir da combinação de elementos de outros gêneros, o que dificulta a diferenciação entre eles.

### 5.1 VERIFICAÇÃO DOS OBJETIVOS PROPOSTOS

Para atingir o objetivo geral deste estudo - classificar gêneros musicais automaticamente por meio da aplicação de algoritmos de Mineração de Dados, considerando a análise de características extraídas do sinal de áudio, foi necessário alcançar quatro objetivos específicos.

O primeiro objetivo específico - identificar características que possam ser extraídas do sinal de áudio - foi alcançado mediante o levantamento bibliográfico por estudos já realizados com temática. Dessa forma, buscou-se identificar quais eram os principais descritores empregados nesta tarefa. Após o levantamento bibliográfico constatou-se que as principais características são aquelas obtidas por meio das análises do sinal no domínio do tempo e no domínio da frequência.

Para o objetivo de extrair características do sinal de áudio de arquivos musicais, empregou-se a ferramenta *jAudio*; uma ferramenta gratuita desenvolvida em Java e que possibilita a extração de descritores do sinal de áudio, tanto no domínio do tempo, quanto no domínio da frequência. Como descritores, extraíram-se os seguintes do domínio do tempo: *Root Mean Square* (RMS), Taxa de Cruzamento Zero (*Zero Crossings*), Baixa Energia (*Fraction of Low Energy Frames*); do domínio da frequência, extraíram-se: Centroide Espectral (*Spectral Centroid*); *Rolloff* Espectral

(*Spectral Rolloff*); Fluxo Espectral (*Spectral Flux*); Coeficientes Cepstrais da frequência Mel - *Mel-frequency cepstral coefficients* (MFCC); *Compactness*.

Para a construção das bases de dados, terceiro objetivo específico, primeiro, identificou-se as 150 músicas mais populares de sete gêneros (*rock, jazz, pop*, música clássica, MPB, *heavy metal* e samba) da Last.fm e, posteriormente, retirou-se as do Youtube. Dessa forma, obteve-se um total de 1.050 registros. Contudo, para este estudo, optou-se por trabalhar com duas bases: uma com os 1.050 registros com duração original; e uma segunda, com 1.050 registros com 30 s de duração cada. Após a construção destas, extraíram-se os descritores listados no objetivo específico número dois.

O quarto objetivo específico - aplicar algoritmos de Mineração de Dados nas bases elaboradas – atingiu-se mediante o uso da ferramenta Weka; na ferramenta, testaram-se 23 algoritmos nas duas bases elaboradas a fim de identificar-se quais apresentavam maior taxa de acerto para as bases. Após este processo, escolheu-se aqueles cujo desempenho de classificação foi superior a 50,00% de acerto, sendo estes: *Random Forest*; *Bagging (Random Forest)*; *AdaBoostM1 (Random Forest)*; *Bagging (Bayes Net)*; *Bayes Net*). Somado a estes cinco algoritmos, optou-se por aplicar os algoritmos SVM e KNN, uma vez que, haja vista a constante utilização destes em trabalhos de classificação de gêneros musicais.

Quanto ao objetivo geral, para aplicar os algoritmos listados no quarto objetivo específico nas duas bases de dados elaboradas, adotou-se três estratégias para a classificação dos gêneros musicais: a) classificação com os sete gêneros musicais (1050 registros); b) classificação com cinco gêneros, sem a presença dos gêneros MPB e Samba (750 registros); e c) classificação com apenas MPB e Samba (300 registros). Desta forma, criaram-se diferentes cenários de classificação, dos quais o melhor cenário apresentou uma taxa de acerto de 66,53% de acerto, para a combinação dos algoritmos *Bagging* e *Bayes Net*.



## 5.2 CONTRIBUIÇÕES

Ao se realizar pesquisas na área de Gestão da Informação por trabalhos semelhantes a este estudo, notou-se que, apesar da Mineração de Dados ser objeto de estudos da área, não existiam trabalhos com objetivos semelhantes aos propostos nesta pesquisa, dessa forma, este estudo apresentou novas possibilidades para a área de Gestão da Informação quanto ao uso da Mineração de Dados para fins de classificação.

Além da contribuição para a ampliação dos estudos de Mineração de Dados na área de Gestão da Informação, neste estudo elaborou-se uma nova base de dados com descritores retirados do sinal do áudio. A base em questão será disponibilizada no repositório *UC Irvine Machine Learning Repository*<sup>7</sup> para que novos estudos sejam realizados por todos aqueles que manifestarem o interesse pelo tema.

## 5.3 TRABALHOS FUTUROS

Como trabalhos futuros sugere-se o emprego de gêneros musicais adicionais, tais como a música eletrônica, uma vez que, trata-se de um gênero com características diferentes dos utilizados neste estudo. Além disso, estimula-se a extração de descritores diferentes do sinal de áudio, como considerar os 13 Coeficientes Cepstrais da frequência Mel e o descritor *Linear Predictive Coding* (LPC).

Sugere-se ainda a aplicação de novos métodos como algoritmos baseados em redes neurais e algoritmos genéticos para a tarefa de classificação.

Finalmente, recomenda-se a utilização de outras ferramentas e técnicas para a extração de descritores e a classificação destes, bem como a utilização de uma base de dados com arquivos com duração diferente da empregada neste estudo, tal como a possibilidade de arquivos com duração de 45 s e 20 s cada.

---

<sup>7</sup> Disponível em: <<http://archive.ics.uci.edu/ml/index.php>>. Acesso em: 08 nov. 2017.

## REFERÊNCIAS

AGRAWAL, R.; IMIELINSKI, T.; SWAMI, A. *Mining association rules between sets of items in large databases. Proceedings of the Acm sigmod record*. ACM, 1993. p. 207-216. Disponível em: <<http://www.almaden.ibm.com/cs/quest/papers/sigmod93.pdf>>. Acesso em: 01 maio 2017.

AGRAWAL, R.; SRIKANT, R. Fast algorithms for mining association rules. In: INTERNATIONAL CONFERENCE ON VERY LARGE DATA BASES, 20., 1994, Santiago de Chile. **Proceedings...** . Santiago de Chile: Vldb, 1994. p. 487 - 499. Disponível em: <[https://www.it.uu.se/edu/course/homepage/infoutv/ht08/vldb94\\_rj.pdf](https://www.it.uu.se/edu/course/homepage/infoutv/ht08/vldb94_rj.pdf)>. Acesso em: 07 maio 2017.

AMARAL, A.; AQUINO, M. C. “Eu recomendo.. e etiqueto”: práticas de folksonomia dos usuários no Last.fm. **Líbero**, São Paulo, v. 12, n. 24, p.117-130, dez. 2009. Disponível em: <<http://www.revistas.univerciencia.org/index.php/libero/article/viewFile/6779/6122>>. Acesso em: 28 maio 2017.

BAEZA-YATES, R.; RIBEIRO-NETO, B. **Recuperação da informação: conceitos e tecnologia das máquinas de busca**. 2. ed. Porto Alegre: Bookman, 2013. 590 p.

BIANCHI, A. J. **Processamento de áudio em tempo real em plataformas computacionais de alta disponibilidade e baixo custo**. 2012. 120 f. Dissertação (Mestrado) - Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, 2012. Disponível em: <<https://www.ime.usp.br/~ajb/projeto/mestrado-ajb.pdf>>. Acesso em: 08 abr. 2017.

BOENTE, A. N. P.; GOLDSCHMIDT, R. R.; ESTRELA, V. V. Uma metodologia de suporte ao processo de descoberta de conhecimento em bases de dados. In: SEGET – SIMPÓSIO DE EXCELÊNCIA EM GESTÃO E TECNOLOGIA, 5., 2008, Resende. **Anais...** . Resende: Aedb, 2008. p. 1 - 14. Disponível em: <<http://boente.eti.br/publica/seget2008KDD.pdf>>. Acesso em: 30 abr. 2017.

BRAGA, L. P. V. **Introdução à mineração de dados**. 2. ed. Rio de Janeiro: E-papers, 2005. 212 p.

BREIMAN, L. Random forests. **Machine Learning**, Boston, v.45, n.1, p.5-32, 2001.

BREIMAN, L. Bagging predictors. **Machine Learning**, Boston, v. 24, n. 2, p.123-140, ago. 1996.

CALIL, L. A. A. et al. Mineração de dados e pós-processamento em padrões descobertos. **Publ. UEPG Ci. Exatas Terra, Ci. Agr. Eng.**, Ponta Grossa, 14 (3):

207-215, dez. 2008. Disponível em:

<<http://www.revistas2.uepg.br/index.php/exatas/article/view/946>>. Acesso em: 07 maio 2017.

CAMILO, C. O.; SILVA, J. C. da. **Mineração de dados**: conceitos, tarefas, métodos e ferramentas. Universidade Federal de Goiás, p. 1- 29, 2009. Disponível em:

<[http://www.inf.ufg.br/sites/default/files/uploads/relatorios-tecnicos/RT-INF\\_001-09.pdf](http://www.inf.ufg.br/sites/default/files/uploads/relatorios-tecnicos/RT-INF_001-09.pdf)>. Acesso em: 30 abr. 2017.

CASEY, M. A. et al. *Content-based music information retrieval: current directions and future challenges*, in *Proceedings of the IEEE*, vol. 96, no. 4, p. 668-696, abr. 2008. Disponível em:

<[http://ieeexplore.ieee.org/ieee\\_pilot/articles/96jproc04/96jproc04-casey/article.html](http://ieeexplore.ieee.org/ieee_pilot/articles/96jproc04/96jproc04-casey/article.html)>. Acesso em: 18 mar. 2017.

CASTILHO, S. **Análise e ressíntese de sinais musicais**. 2008. 133 f. Dissertação (Mestrado) - Curso de Matemática, Matemática e Computação Científica,

Universidade Federal de Santa Catarina, Florianópolis, 2008. Disponível em: <[http://mtm.ufsc.br/pos/Saulo\\_Castilho.pdf](http://mtm.ufsc.br/pos/Saulo_Castilho.pdf)>. Acesso em: 14 abr. 2017.

CASTRO, L. N.; FERRARI, D. G. **Introdução à mineração de dados**: conceitos básicos, algoritmos e aplicações. São Paulo: Saraiva, 2016.

CENDROWSKA, J. PRISM: An algorithm for inducing modular rules. **International Journal of Man-Machine Studies**, v. 27, n. 4, p. 349-370, 1987.

COOLEY, J. W.; TUKEY, J. W. *An algorithm for the machine calculation of complex Fourier series*. **Mathematics of computation**, v. 19, n. 90, p. 297-301, 1965.

Disponível em: <<http://www.ams.org/journals/mcom/1965-19-090/S0025-5718-1965-0178586-1/S0025-5718-1965-0178586-1.pdf>>. Acesso em: 14 abr. 2017.

CORREA, D. C. **Inteligência artificial aplicada à análise de gêneros musicais**.

2012. 175p. Tese (Doutorado em Física Aplicada) - Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos, 2012. Disponível em:

<<http://www.teses.usp.br/teses/disponiveis/76/76132/tde-05032013-090334/en.php>>. Acesso em: 07 maio 2017.

COSTA, C. H. L.; VALLE, J. D.; KOERICH, A. L. *Automatic classification of audio data*. In: **Systems, Man and Cybernetics, 2004 IEEE International Conference on**. IEEE, 2004. p. 562-567. Disponível em:

<<http://www.ppgia.pucpr.br/~alekoe/Papers/ALEKOE-SMC-2004.pdf>>. Acesso em: 16 abr. 2017.

COSTA, Y. M. e G. da. **Reconhecimento de gêneros musicais utilizando espectogramas com combinação de classificadores**. 2013. 106 f. Tese

(Doutorado) - Curso de Ciência da Computação, Informática, Universidade Federal do Paraná, Curitiba, 2013. Disponível em:

<<http://acervodigital.ufpr.br/bitstream/handle/1884/34886/R%20-%20T%20>

%20YANDRE%20MALDONADO%20E%20GOMES%20DA%20COSTA.pdf?sequence=1 >. Acesso em: 16 abr. 2017.

COVER, T.; HART, P. Nearest neighbor pattern classification. **Ieee Transactions On Information Theory**, [s.l.], v. 13, n. 1, p.21-27, jan. 1967. Institute of Electrical and Electronics Engineers (IEEE)

DANTAS, E. R.I G. et al. O uso da descoberta de conhecimento em base de dados para apoiar a tomada de decisões. **V Simpósio de Excelência em Gestão e Tecnologia-SEGeT**, Resende, v. 1, p. 50 - 60, 2008. Disponível em: <[http://www.professores.aedb.br/seget/artigos08/331\\_331\\_Artigo\\_SEGET\\_EJDR\\_Versao\\_Final\\_010808.pdf](http://www.professores.aedb.br/seget/artigos08/331_331_Artigo_SEGET_EJDR_Versao_Final_010808.pdf)>. Acesso em: 30 abr. 2017.

DESHPANDE, H.; SINGH, R.; NAM, U. *Classification of music signals in the visual domain*. In: **Proceedings of the COST-G6 Conference on Digital Audio Effects**. sn, 2001. p. 1-4. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.13.4634&rep=rep1&type=pdf>>. Acesso em: 16 abr. 2017.

DIAS, M. M. Parâmetros na escolha de técnicas e ferramentas de mineração de dados. **Acta Scientiarum. Technology**, Maringá, v. 6, n. 24, p.1715-1725, jun. 2002. Disponível em: <<http://ojs.uem.br/ojs/index.php/ActaSciTechnol/article/view/2549/1569>>. Acesso em: 07 maio 2017.

DINIZ, P. S. R.; SILVA, E. A. B. da; NETTO, S. L. **Processamento digital de sinais: Projeto e Análise de Sistemas**. 2. ed. Porto Alegre: Bookman, 2014.

DORIER, M. *Content-based music information retrieval from sound waves to musical characteristics*. ENS Cachan Brittany University of Rennes I. 2011. Disponível em: <[http://people.irisa.fr/Matthieu.Dorier/docs/CDD\\_synthesis\\_MatthieuDorier.pdf](http://people.irisa.fr/Matthieu.Dorier/docs/CDD_synthesis_MatthieuDorier.pdf)>. Acesso em: 18 mar. 2017.

FARIA, R. R. A. **Aplicação de wavelets na análise de gestos musicais em timbres de instrumentos acústicos tradicionais**. 1997. 203 f. Dissertação (Mestrado) - Curso de Engenharia, Escola Politécnica da Universidade de São Paulo, São Paulo, 1997. Disponível em: <<http://www.organia.com.br/sites/regist/DissertacaoMSc-RegisFaria.pdf>>. Acesso em: 09 abr. 2017.

FAYYAD, U.; PIATETSKY-SHAPIO, G.; SMYTH, P. *From data mining to knowledge discovery in databases*. **AI magazine**, v. 17, n. 3, p. 37-54, 1996a. Disponível em: <<http://www.csd.uwo.ca/faculty/ling/cs435/fayyad.pdf>>. Acesso em 22 abr. 2017.

\_\_\_\_\_. Knowledge discovery and data mining: towards a unifying framework. In: SECOND INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING (KDD-96), 2., 1996b, Portland. **Proceedings...** . Portland: Aaa Press,

1996. p. 1 - 8. Disponível em:

<<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.27.363&rep=rep1&type=pdf>>. Acesso em: 22 abr. 2017.

\_\_\_\_\_. The KDD process for extracting useful knowledge from volumes of data. **Communications of the ACM**, v. 39, n. 11, p. 27-34, 1996c. Disponível em: <<http://dl.acm.org/citation.cfm?id=240464>>. Acesso em: 22 abr. 2017.

FERNEDA, E. **Recuperação de informação: análise sobre a contribuição da ciência da computação para a ciência da informação**. 2003. 137 f. Tese (Doutorado) - Curso de Ciências da Comunicação, Universidade de São Paulo, São Paulo, 2003. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/27/27143/tde-15032004-130230/publico/Tese.pdf>>. Acesso em: 02 abr. 2017.

FREUND, Y.; SCHAPIRE, R. A decision-theoretic generalization of on-line learning and an application to boosting. **Journal of Computer and System Sciences**, p. 23–37, 1997.

FREUND, Y.; SCHAPIRE, R. A short introduction to boosting. **Journal-Japanese Society For Artificial Intelligence**, v. 14, n. 771-780, p. 1612, 1999.

FRIEDMAN, N.; GEIGER, D.; GOLDSZMIDT, M. Bayesian network classifiers. **Machine learning**, v. 29, n. 2-3, p. 131-163, 1997.

GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008.

GJERDINGEN, R. O.; PERROTT, D. *Scanning the dial: The rapid recognition of music genres*. **Journal of New Music Research**, v. 37, n. 2, p. 93-100, 2008. Disponível em: <<http://faculty-web.at.northwestern.edu/music/gjerdingen/Papers/PubPapers/Scanning.pdf>>. Acesso em: 16 abr. 2017.

GOLDSCHMIDT, R.; PASSOS, E. **Data mining: um guia prático**. Rio de Janeiro: Campus, 2005.

GOULART, A. J. H. **Classificação automática de gênero musical baseada em entropia e fractais**. 2012. 143 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade de São Paulo, São Carlos, 2012. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/18/18153/tde-16032012-152801/pt-br.php>>. Acesso em: 20 jul. 2017.

GRIMALDI, M.; CUNNINGHAM, P.; KOKARAM, A. *A wavelet packet representation of audio signals for music genre classification using different ensemble and feature selection techniques*. In: **Proceedings of the 5th ACM SIGMM international workshop on Multimedia information retrieval**. ACM, 2003. p. 102-108. Disponível em: <<http://dl.acm.org/citation.cfm?id=973281>>. Acesso em: 16 abr. 2017.

HAYKIN, S.; VAN VEEN, B. **Sinais e sistemas**. Porto Alegre: Bookman, 2001.

HU, X. **Knowledge discovery in databases: an attribute-oriented rough set approach**. 1995. 152 f. Tese (Doutorado) - Curso de Ciência da Computação, University Of Regina, Regina, 1995. Disponível em: <<https://pdfs.semanticscholar.org/f72c/6f7e487df945e7a87454c5bde40d2306e771.pdf>>. Acesso em: 23 abr. 2017.

JAIN, A. K. Data clustering: 50 years beyond k-means. **Pattern Recognition Letters**, v. 31, n. 8, 2010, p. 651-666.

JOHN, G. H.; LANGLEY, P. Estimating continuous distributions in Bayesian classifiers. In: **PROCEEDINGS OF THE ELEVENTH CONFERENCE ON UNCERTAINTY IN ARTIFICIAL INTELLIGENCE**. Morgan Kaufmann Publishers Inc., 1995. p. 338-345.

KNOPKE, I. Sound, Music and Textual Associations on the World Wide Web. In: International Symposium on Music Information Retrieval (ISMIR), 2004. **Proceedings...** . ISMIR, 2004, p. 484-488. Disponível em: <[http://s3.amazonaws.com/academia.edu.documents/34678774/p088-page-484-paper244.pdf?AWSAccessKeyId=AKIAIWOWYYGZ2Y53UL3A&Expires=1495391781&Signature=D9kHjKL7mexzZPN7wUdZXd6zs4U%3D&response-content-disposition=inline%3B%20filename%3DSound\\_Music\\_and\\_Textual\\_Associations\\_on.pdf](http://s3.amazonaws.com/academia.edu.documents/34678774/p088-page-484-paper244.pdf?AWSAccessKeyId=AKIAIWOWYYGZ2Y53UL3A&Expires=1495391781&Signature=D9kHjKL7mexzZPN7wUdZXd6zs4U%3D&response-content-disposition=inline%3B%20filename%3DSound_Music_and_Textual_Associations_on.pdf)>. Acesso em: 21 maio 2017.

KUO, F. F. et al. Emotion-based music recommendation by association discovery from film music. In: 13th annual ACM international conference on Multimedia (MULTIMEDIA '05), 13., 2005, Nova Iorque . **Proceedings...** . Nova Iorque: ACM, 2005, p. 507-510. Disponível em: <<http://dl.acm.org/citation.cfm?id=1101263>>. Acesso em: 21 maio 2017.

LI, T.; LI, L. **Music data mining**: an introduction. 2010. Disponível em: <<https://pdfs.semanticscholar.org/6ca7/b53455585b484afef120cfea75ebfc84f7d6.pdf>>. Acesso em: 21 maio 2017.

LI, T.; OGIHARA, M.; LI, Q. *A comparative study on content-based music genre classification*. In: **Proceedings of the 26th annual international ACM SIGIR conference on Research and development in informaion retrieval**. ACM, 2003. p. 282-289. Disponível em: <<http://dl.acm.org/citation.cfm?id=860487>>. Acesso em: 16 abr. 2017.

LI, T.; OGIHARA, M.; TZANETAKIS, G. **Music data mining**. Boca Raton: Crc Press, 2011. 384 p.

LINOFF, G.; BERRY, M. J. A. **Data mining techniques: for marketing, sales, and customer support**. 3. ed. Indianapolis: Wiley Publishing, Inc., 2011.

LOPES, I. L. Estratégia de busca na recuperação da informação: revisão da literatura. **Ci. Inf.**, Brasília, v. 31, n. 2, p. 60-71, maio/ago. 2002. Disponível em: <<http://www.scielo.br/pdf/%0D/ci/v31n2/12909.pdf> >. Acesso em: 02 abr. 2017.

MALHEIRO, R. M. da S. **Sistemas de classificação automática em gêneros musicais**. 2003. 152 f. Dissertação (Mestrado) - Curso de Engenharia Informática, Departamento de Engenharia Informática, Universidade de Coimbra, Coimbra, 2003. Disponível em: <[http://www.academia.edu/671728/Sistemas\\_de\\_Classificação\\_Automática\\_em\\_Gêneros\\_Musicais](http://www.academia.edu/671728/Sistemas_de_Classificação_Automática_em_Gêneros_Musicais)>. Acesso em: 08 abr. 2017.

McAdams, S. 1999. Perspectives on the contribution of timbre to musical structure. **Computer Music Journal**, p. 85–102. Disponível em: <<http://cmc.music.columbia.edu/courses/g6610/fall2011/week4/McAdams-timbre-structure.pdf>>. Acesso em: 19 nov. 2017.

MCKAY, C. **Automatic music classification with jMIR**. 2010. 600 f. Tese (Doutorado) - Music Technology, McGill University, Montreal, 2010. Disponível em: <[http://jmir.sourceforge.net/publications/PhD\\_Dissertation\\_2010.pdf](http://jmir.sourceforge.net/publications/PhD_Dissertation_2010.pdf)>. Acesso em: 27 maio 2017.

MCKAY, C.; FUJINAGA, I. JMIR: tools for automatic music classification. In: INTERNATIONAL COMPUTER MUSIC CONFERENCE, 4., 2009, Montreal. **Proceedings...** . Montreal: ICMC, 2009. p. 65 - 68. Disponível em: <<http://quod.lib.umich.edu/cgi/p/pod/dod-idx/jmir-tools-for-automatic-music-classification.pdf?c=icmc;idno=bbp2372.2009.014>>. Acesso em: 28 maio 2017.

PADOVANI, J. H.; FREIRE, S. Explorando envoltórias espectrais em sistemas musicais interativos. In: Congresso da Associação Nacional de Pesquisa e Pós-graduação em Música (ANPPOM), 16., 2006, Brasília. **Anais...** . Brasília: Anppom, 2006. p. 280 - 287. Disponível em: <[http://www4.unirio.br/mpb/textos/AnaisANPPOM/Anppom 2006/060830\\_1122 \(D\)/CDROM/COM/03\\_Com\\_InfMus/sessao02/03COM\\_InfMus\\_0201-189.pdf](http://www4.unirio.br/mpb/textos/AnaisANPPOM/Anppom%202006/060830_1122(D)/CDROM/COM/03_Com_InfMus/sessao02/03COM_InfMus_0201-189.pdf)> . Acesso em: 09 abr. 2017.

PAGE, L. et al. **The PageRank citation ranking: Bringing order to the web**. Stanford InfoLab, 1999. Disponível em: <<http://ilpubs.stanford.edu:8090/422/1/1999-66.pdf>>. Acesso em: 02 abr. 2017.

PIASECKI FILHO, W. L. **Estudo comparativo entre os algoritmos de processamento de áudio phase vocoder e spectral modeling synthesis** . 2011. 50 f. TCC (Graduação) - Curso de Tecnologia em Sistemas Para Internet, Departamento Acadêmico de Informática, Universidade Tecnológica Federal do Paraná, Curitiba, 2011. Disponível em: <[http://repositorio.roca.utfpr.edu.br/jspui/bitstream/1/725/1/CT\\_COTSI\\_2011\\_2\\_12.pdf](http://repositorio.roca.utfpr.edu.br/jspui/bitstream/1/725/1/CT_COTSI_2011_2_12.pdf)>. Acesso em: 14 abr. 2017.

PIRES, A. S. **Métodos de segmentação musical baseados em descritores sonoros**. 2011. 178 f. Dissertação (Mestrado) - Curso de Ciências da Computação, Instituto de Matemática e Estatística da Universidade de São Paulo, São Paulo, 2011. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/45/45134/tde-14082011-204700/en.php>>. Acesso em: 10 maio 2017.

QUILICI-GONZALEZ, J. A.; ZAMPIROLI, F. A. de. **Sistemas Inteligentes e Mineração de Dados**. Santo André: Triunfal Gráfica e Editora, 2014. 148 p.

QUINLAN, J. R. Induction of decision trees. **Machine learning**, Boston, v. 1, n. 1, p. 81-106, 01 mar. 1986.

QUINLAN, J. R. **C4.5**: Programs for machine learning. Sam Mateo: Morgan Kaufmann, 1993.

REZENDE, D. D. de. **Um modelo de classificação supervisionada com rotulagem automática para reconhecimento de áudio de web rádios**. 2014. 84 f. Dissertação (Mestrado) - Curso de Ciência da Computação, Departamento de Ciência da Computação, Universidade Federal de Ouro Preto, Ouro Preto, 2014. Disponível em: <[http://www.decom.ufop.br/pos/site\\_media/uploads\\_ppgcc/publicacao/rezende2014.pdf](http://www.decom.ufop.br/pos/site_media/uploads_ppgcc/publicacao/rezende2014.pdf)>. Acesso em: 18 mar. 2017.

ROKACH, L.; MAIMON, O. **Data mining with decision trees: theory and applications**. [s.l.]: World Scientific Publishing, 2008.

SALAZAR, A. E. C. **Mineração de estruturas musicais e composição automática utilizando redes complexas**. 2015. 171 f. Tese (Doutorado) - Curso de Ciências da Computação, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2015. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/55/55134/tde-10082015-100252/pt-br.php>>. Acesso em: 12 abr. 2017.

SILLA JR, C. N.; KAESTNER, C. AA; KOERICH, A. L. Classificação de gêneros musicais utilizando vetores de característica híbridos. **13º Simpósio Brasileiro de Computação Musical (SBCM 2011)**, p. 32-44, 2011. Disponível em: <<https://pdfs.semanticscholar.org/08ab/8c71f763d8ba412d6a78cc2fca332a6714bd.pdf>>. Acesso em: 16 abr. 2017.

SILLA JUNIOR, C.N.; KAESTNER, C. A. A.; KOERICH, A. L. Classificação automática de gêneros musicais utilizando métodos de *Bagging* e *Boosting*. In: BRAZILIAN SYMPOSIUM ON COMPUTER MUSIC (SBCM), 10., 2005, Belo Horizonte. **Anais...** . Belo Horizonte: Sbcm, 2005. p. 48 - 57. Disponível em: <<http://www.ppgia.pucpr.br/~alekoe/Papers/Koerich-SBCM2005.pdf>>. Acesso em: 29 maio 2017.

SILVA, M. A. G. da. **Filtros digitais aplicados em sinais de audio**. 2007. 62 f. TCC (Graduação) - Curso de Ciência da Computação, Instituto de Ciências Exatas da



Universidade Federal de Juiz de Fora, Juiz de Fora, 2007. Disponível em: <<http://www.gcg.ufjf.br/pub/doc49.pdf>>. Acesso em: 08 abr. 2017.

SOUZA FILHO, M. da C. **Classificação automática de gêneros de áudio digital**. 2006. 60 f. TCC (Graduação) - Curso de Engenharia da Computação, Universidade de Pernambuco, Recife, 2006. Disponível em: <<http://tcc.ecomp.poli.br/20062/MoacirFilho.pdf>>. Acesso em: 08 abr. 2017.

SRIKANT, R; VU, Q; AGRAWAL, R. *Mining association rules with item constraints*. In: THE THIRD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING (KDD-97), 3., 1997, Newport Beach. **Proceedings...** . Newport Beach: Aaii, 1997. p. 67 - 73. Disponível em: <<http://www.aaai.org/Papers/KDD/1997/KDD97-011.pdf>>. Acesso em: 07 maio 2017.

TSUNODA, D. F. **Abordagens evolucionárias para a descoberta de padrões e classificação de proteínas**. 2004. 177 f. Tese (Doutorado) - Curso de Engenharia Elétrica e Informática Industrial, Cefet-pr, Curitiba, 2004. Disponível em: <[http://files.dirppg.ct.utfpr.edu.br/cpgei/Ano\\_2004/teses/Tese\\_008\\_2004.pdf](http://files.dirppg.ct.utfpr.edu.br/cpgei/Ano_2004/teses/Tese_008_2004.pdf)>. Acesso em: 23 abr. 2017.

TWO CROWS CORPORATION. **Introduction to data mining and knowledge Discovery**. 3.ed. Potomac: Two Crows, 2005. 36 p.

TYPKE, R.; Wiering, F.; Veltkamp, R.C . *A survey of music information retrieval systems*. In: **Ismir**. 2005. p. 153-160. Disponível em: <[https://www.researchgate.net/profile/Remco\\_Veltkamp/publication/220723096\\_A\\_Survey\\_of\\_Music\\_Information\\_Retrieval\\_Systems/links/0deec51df16a5d53e6000000/A-Survey-of-Music-Information-Retrieval-Systems.pdf](https://www.researchgate.net/profile/Remco_Veltkamp/publication/220723096_A_Survey_of_Music_Information_Retrieval_Systems/links/0deec51df16a5d53e6000000/A-Survey-of-Music-Information-Retrieval-Systems.pdf)>. Acesso em: 18 mar. 2017.

TZANETAKIS, G. **Manipulation, analysis and retrieval systems for audio signals**. 2002. 184 f. Tese (Doutorado) - Curso de Philosophy, Computer Science, Princeton University, Princeton, 2002. Disponível em: <<http://webhome.cs.uvic.ca/~gtzan/work/pubs/thesis02gtzan.pdf>>. Acesso em: 26 mar. 2017.

TZANETAKIS, G.; COOK, P. *Musical genre classification of audio signals*. **IEEE Transactions on speech and audio processing**, v. 10, n. 5, p. 293-302, 2002. Disponível em: <<http://ieeexplore.ieee.org/abstract/document/1021072/>>. Acesso em: 16 abr. 2017.

UJLAMBKAR, A. M. **Automatic mood classification of indian popular music**. 2012. 54 f. Dissertação (Mestrado) - Technology and Computer Engineering, Department Of Computer Engineering And Information Technology, College Of Engineering, Pune, Pune, 2012. Disponível em: <[http://www.coep.org.in/page\\_assets/341/121022001.pdf](http://www.coep.org.in/page_assets/341/121022001.pdf)>. Acesso em: 18 mar. 2017.

VAPNIK, V. **Estimation of dependences based on empirical data**. New York: Springer Science & Business Media, 2006.

VAPNIK, V. **The nature of statistical learning theory**. Springer science & business media, 2013.

WU, X. et al. *Top 10 algorithms in data mining*. **Knowledge and information systems**, v. 14, n. 1, p. 1-37, 2008.

XIAO, L. et al. Using a statistic model to capture the association between timbre and perceived tempo. In: International Conference on Music Information Retrieval, 2008. **Proceedings...** . ISMIR, 2008, p. 659–662. Disponível em: <<http://ai2-s2-pdfs.s3.amazonaws.com/ab6b/487b360868bc83580775bf02e2f4315add35.pdf>>. Acesso em: 21 maio 2017.

## APÊNDICE A– LISTA DAS MÚSICAS UTILIZADAS NESTE ESTUDO

<b>Título</b>	<b>Artista</b>	<b>Gênero</b>
Paranoid	Black Sabbath	Heavy Metal
Run to the Hills	Iron Maiden	Heavy Metal
The Number of the Beast	Iron Maiden	Heavy Metal
Iron Man	Black Sabbath	Heavy Metal
Ace of Spades	Motörhead	Heavy Metal
The Trooper	Iron Maiden	Heavy Metal
Fear of the Dark	Iron Maiden	Heavy Metal
Enter Sandman	Metallica	Heavy Metal
Master of Puppets	Metallica	Heavy Metal
Painkiller	Judas Priest	Heavy Metal
Nothing Else Matters	Metallica	Heavy Metal
2 Minutes to Midnight	Iron Maiden	Heavy Metal
Breaking the Law	Judas Priest	Heavy Metal
Aces High	Iron Maiden	Heavy Metal
Hallowed Be Thy Name	Iron Maiden	Heavy Metal
War Pigs	Black Sabbath	Heavy Metal
Holy Diver	Dio	Heavy Metal
Crazy Train	Ozzy Osbourne	Heavy Metal
The Unforgiven	Metallica	Heavy Metal
One	Metallica	Heavy Metal
Wasted Years	Iron Maiden	Heavy Metal
Sad but True	Metallica	Heavy Metal
Black Sabbath	Black Sabbath	Heavy Metal
Rainbow in the Dark	Dio	Heavy Metal
Fade to Black	Metallica	Heavy Metal
Children of the Grave	Black Sabbath	Heavy Metal
Heaven and Hell	Black Sabbath	Heavy Metal
The Evil That Men Do	Iron Maiden	Heavy Metal
Mr. Crowley	Ozzy Osbourne	Heavy Metal
The Wicker Man	Iron Maiden	Heavy Metal
Can I Play With Madness	Iron Maiden	Heavy Metal
Symphony of Destruction	Megadeth	Heavy Metal
Cowboys from Hell	Pantera	Heavy Metal
Sabbath Bloody Sabbath	Black Sabbath	Heavy Metal
Electric Funeral	Black Sabbath	Heavy Metal
For Whom the Bell Tolls	Metallica	Heavy Metal
Living After Midnight	Judas Priest	Heavy Metal
Flight of Icarus	Iron Maiden	Heavy Metal
Brave New World	Iron Maiden	Heavy Metal

The Wizard	Black Sabbath	Heavy Metal
Rime of the Ancient Mariner	Iron Maiden	Heavy Metal
Battery	Metallica	Heavy Metal
The Day That Never Comes	Metallica	Heavy Metal
Highway to Hell	AC/DC	Heavy Metal
Whiskey in the Jar	Metallica	Heavy Metal
Electric Eye	Judas Priest	Heavy Metal
Dance of Death	Iron Maiden	Heavy Metal
Wherever I May Roam	Metallica	Heavy Metal
Bark at the Moon	Ozzy Osbourne	Heavy Metal
Phantom of the Opera	Iron Maiden	Heavy Metal
Blood Brothers	Iron Maiden	Heavy Metal
Balls to the Wall	Accept	Heavy Metal
Powerslave	Iron Maiden	Heavy Metal
Sweet Leaf	Black Sabbath	Heavy Metal
Back in Black	AC/DC	Heavy Metal
N.I.B.	Black Sabbath	Heavy Metal
Kings of Metal	Manowar	Heavy Metal
Warriors of the World United	Manowar	Heavy Metal
Don't Talk to Strangers	Dio	Heavy Metal
Fuel	Metallica	Heavy Metal
Planet Caravan	Black Sabbath	Heavy Metal
Iron Maiden	Iron Maiden	Heavy Metal
Be Quick or Be Dead	Iron Maiden	Heavy Metal
Wrathchild	Iron Maiden	Heavy Metal
You've Got Another Thing Comin'	Judas Priest	Heavy Metal
Walk	Pantera	Heavy Metal
Revelations	Iron Maiden	Heavy Metal
A Touch of Evil	Judas Priest	Heavy Metal
The Unforgiven II	Metallica	Heavy Metal
Rainmaker	Iron Maiden	Heavy Metal
Children of the Damned	Iron Maiden	Heavy Metal
No More Lies	Iron Maiden	Heavy Metal
Welcome Home (Sanitarium)	Metallica	Heavy Metal
The Clairvoyant	Iron Maiden	Heavy Metal
Afraid to Shoot Strangers	Iron Maiden	Heavy Metal
Raining Blood	Slayer	Heavy Metal
Wait and Bleed	Slipknot	Heavy Metal
Prowler	Iron Maiden	Heavy Metal
Hail and Kill	Manowar	Heavy Metal
Infinite Dreams	Iron Maiden	Heavy Metal
Stand Up and Shout	Dio	Heavy Metal
Hangar 18	Megadeth	Heavy Metal

Into the Void	Black Sabbath	Heavy Metal
No More Tears	Ozzy Osbourne	Heavy Metal
Metal Meltdown	Judas Priest	Heavy Metal
Creeping Death	Metallica	Heavy Metal
Rock You Like a Hurricane	Scorpions	Heavy Metal
Running Free	Iron Maiden	Heavy Metal
Ghost of the Navigator	Iron Maiden	Heavy Metal
Hand of Doom	Black Sabbath	Heavy Metal
Different World	Iron Maiden	Heavy Metal
The Prisoner	Iron Maiden	Heavy Metal
Wasting Love	Iron Maiden	Heavy Metal
Night Crawler	Judas Priest	Heavy Metal
Cemetery Gates	Pantera	Heavy Metal
Where Eagles Dare	Iron Maiden	Heavy Metal
Metal Gods	Judas Priest	Heavy Metal
Turbo Lover	Judas Priest	Heavy Metal
Overkill	Motörhead	Heavy Metal
Seventh Son of a Seventh Son	Iron Maiden	Heavy Metal
Before I Forget	Slipknot	Heavy Metal
Hell Patrol	Judas Priest	Heavy Metal
Of Wolf and Man	Metallica	Heavy Metal
Mother	Danzig	Heavy Metal
Fairies Wear Boots	Black Sabbath	Heavy Metal
Neon Knights	Black Sabbath	Heavy Metal
I Want Out	Helloween	Heavy Metal
The Memory Remains	Metallica	Heavy Metal
I Just Want You	Ozzy Osbourne	Heavy Metal
Paschendale	Iron Maiden	Heavy Metal
Tears of the Dragon	Bruce Dickinson	Heavy Metal
22 Acacia Avenue	Iron Maiden	Heavy Metal
Ride the Lightning	Metallica	Heavy Metal
Mama, I'm Coming Home	Ozzy Osbourne	Heavy Metal
I Wanna Be Somebody	W.A.S.P.	Heavy Metal
Angel of Death	Slayer	Heavy Metal
Thunderstruck	AC/DC	Heavy Metal
Metal Heart	Accept	Heavy Metal
Peace Sells	Megadeth	Heavy Metal
Snowblind	Black Sabbath	Heavy Metal
Highway Star	Deep Purple	Heavy Metal
Flash of the Blade	Iron Maiden	Heavy Metal
A Tout le Monde	Megadeth	Heavy Metal
Hard Rock Hallelujah	Lordi	Heavy Metal
Supernaut	Black Sabbath	Heavy Metal

The Gods Made Heavy Metal	Manowar	Heavy Metal
Princess of the Night	Saxon	Heavy Metal
Dream of Mirrors	Iron Maiden	Heavy Metal
The Thing That Should Not Be	Metallica	Heavy Metal
Children of the Sea	Black Sabbath	Heavy Metal
Until It Sleeps	Metallica	Heavy Metal
We Rock	Dio	Heavy Metal
My Friend of Misery	Metallica	Heavy Metal
Hells Bells	AC/DC	Heavy Metal
The Call of Ktulu	Metallica	Heavy Metal
Leather Rebel	Judas Priest	Heavy Metal
Die With Your Boots On	Iron Maiden	Heavy Metal
Killers	Iron Maiden	Heavy Metal
Caught Somewhere In Time	Iron Maiden	Heavy Metal
Kingdom Come	Manowar	Heavy Metal
Holy Smoke	Iron Maiden	Heavy Metal
All Nightmare Long	Metallica	Heavy Metal
Moonchild	Iron Maiden	Heavy Metal
I Don't Wanna Stop	Ozzy Osbourne	Heavy Metal
Victim of Changes	Judas Priest	Heavy Metal
The God That Failed	Metallica	Heavy Metal
Invaders	Iron Maiden	Heavy Metal
Smoke on the Water	Deep Purple	Heavy Metal
All Guns Blazing	Judas Priest	Heavy Metal
Transylvania	Iron Maiden	Heavy Metal
Smells Like Teen Spirit	Nirvana	ROCK
Wonderwall	Oasis	ROCK
Zombie	The Cranberries	ROCK
Stairway to Heaven	Led Zeppelin	ROCK
Californication	Red Hot Chili Peppers	ROCK
Somebody Told Me	The Killers	ROCK
Come as You Are	Nirvana	ROCK
Bohemian Rhapsody	Queen	ROCK
Boulevard of Broken Dreams	Green Day	ROCK
Dani California	Red Hot Chili Peppers	ROCK
Sweet Child o' Mine	Guns N' Roses	ROCK
Seven Nation Army	The White Stripes	ROCK
With or Without You	U2	ROCK
Song 2	Blur	ROCK
Under the Bridge	Red Hot Chili Peppers	ROCK
Starlight	Muse	ROCK
Viva la Vida	Coldplay	ROCK
Bring Me to Life	Evanescence	ROCK

Supermassive Black Hole	Muse	ROCK
Take Me Out	Franz Ferdinand	ROCK
The Pretender	Foo Fighters	ROCK
Beautiful Day	U2	ROCK
Paint It Black	The Rolling Stones	ROCK
November Rain	Guns N' Roses	ROCK
Clocks	Coldplay	ROCK
Hotel California	Eagles	ROCK
How You Remind Me	Nickelback	ROCK
Iris	Goo Goo Dolls	ROCK
Creep	Radiohead	ROCK
Sex on Fire	Kings of Leon	ROCK
Time Is Running Out	Muse	ROCK
Welcome to the Jungle	Guns N' Roses	ROCK
Smoke on the Water	Deep Purple	ROCK
Everlong	Foo Fighters	ROCK
When You Were Young	The Killers	ROCK
Here Without You	3 Doors Down	ROCK
Kryptonite	3 Doors Down	ROCK
Mr. Brightside	The Killers	ROCK
In the End	Linkin Park	ROCK
Sultans of Swing	Dire Straits	ROCK
Karma Police	Radiohead	ROCK
Otherside	Red Hot Chili Peppers	ROCK
Losing My Religion	R.E.M.	ROCK
We Will Rock You	Queen	ROCK
I Don't Want to Miss a Thing	Aerosmith	ROCK
One	U2	ROCK
Are You Gonna Be My Girl	Jet	ROCK
Paradise City	Guns N' Roses	ROCK
Lithium	Nirvana	ROCK
Sunday Bloody Sunday	U2	ROCK
Hysteria	Muse	ROCK
My Immortal	Evanescence	ROCK
Scar Tissue	Red Hot Chili Peppers	ROCK
Dream On	Aerosmith	ROCK
The Scientist	Coldplay	ROCK
Yellow	Coldplay	ROCK
What I've Done	Linkin Park	ROCK
Vertigo	U2	ROCK
Killing in the Name	Rage Against the Machine	ROCK
Highway to Hell	AC/DC	ROCK
Numb	Linkin Park	ROCK

Use Somebody	Kings of Leon	ROCK
Wish You Were Here	Pink Floyd	ROCK
Knights of Cydonia	Muse	ROCK
Nothing Else Matters	Metallica	ROCK
Baba O'Riley	The Who	ROCK
Rockstar	Nickelback	ROCK
By the Way	Red Hot Chili Peppers	ROCK
No One Knows	Queens of the Stone Age	ROCK
The Reason	Hoobastank	ROCK
Black Hole Sun	Soundgarden	ROCK
Back in Black	AC/DC	ROCK
Money for Nothing	Dire Straits	ROCK
Another One Bites the Dust	Queen	ROCK
Chasing Cars	Snow Patrol	ROCK
Eye of the Tiger	Survivor	ROCK
Every Breath You Take	The Police	ROCK
Don't Look Back in Anger	Oasis	ROCK
Sweet Home Alabama	Lynyrd Skynyrd	ROCK
The Kill	30 Seconds to Mars	ROCK
Learn to Fly	Foo Fighters	ROCK
Fix You	Coldplay	ROCK
Best of You	Foo Fighters	ROCK
I Still Haven't Found What I'm Looking For	U2	ROCK
Sympathy for the Devil	The Rolling Stones	ROCK
Knockin' on Heaven's Door	Guns N' Roses	ROCK
Don't Speak	No Doubt	ROCK
Crazy	Aerosmith	ROCK
Fly Away	Lenny Kravitz	ROCK
If Everyone Cared	Nickelback	ROCK
Paranoid	Black Sabbath	ROCK
It's My Life	Bon Jovi	ROCK
I Hate Everything About You	Three Days Grace	ROCK
Light My Fire	The Doors	ROCK
More Than a Feeling	Boston	ROCK
Where the Streets Have No Name	U2	ROCK
Going Under	Evanescence	ROCK
The Show Must Go On	Queen	ROCK
Behind Blue Eyes	Limp Bizkit	ROCK
Wind of Change	Scorpions	ROCK
Alive	Pearl Jam	ROCK
From Yesterday	30 Seconds to Mars	ROCK
Livin' on a Prayer	Bon Jovi	ROCK
All Along the Watchtower	Jimi Hendrix	ROCK



Holiday	Green Day	ROCK
Brothers in Arms	Dire Straits	ROCK
Roxanne	The Police	ROCK
Misery Business	Paramore	ROCK
Rape Me	Nirvana	ROCK
Every You Every Me	Placebo	ROCK
Be Yourself	Audioslave	ROCK
We Are the Champions	Queen	ROCK
Like a Stone	Audioslave	ROCK
Don't Stop Me Now	Queen	ROCK
Snow (Hey Oh)	Red Hot Chili Peppers	ROCK
Message in a Bottle	The Police	ROCK
Violet Hill	Coldplay	ROCK
Faint	Linkin Park	ROCK
Sunshine of Your Love	Cream	ROCK
The Final Countdown	Europe	ROCK
People Are Strange	The Doors	ROCK
Welcome to the Black Parade	My Chemical Romance	ROCK
Ruby	Kaiser Chiefs	ROCK
Immigrant Song	Led Zeppelin	ROCK
Paranoid Android	Radiohead	ROCK
You Shook Me All Night Long	AC/DC	ROCK
All My Life	Foo Fighters	ROCK
1979	The Smashing Pumpkins	ROCK
All These Things That I've Done	The Killers	ROCK
Whole Lotta Love	Led Zeppelin	ROCK
Speed of Sound	Coldplay	ROCK
Summer of '69	Bryan Adams	ROCK
Come Together	The Beatles	ROCK
Pride (in the Name of Love)	U2	ROCK
American Idiot	Green Day	ROCK
Comfortably Numb	Pink Floyd	ROCK
Lonely Day	System of a Down	ROCK
Riders on the Storm	The Doors	ROCK
Smile Like You Mean It	The Killers	ROCK
Bitter Sweet Symphony	The Verve	ROCK
Gimme Shelter	The Rolling Stones	ROCK
In Bloom	Nirvana	ROCK
My Generation	The Who	ROCK
The Bitter End	Placebo	ROCK
Born to Be Wild	Steppenwolf	ROCK
Can't Stop	Red Hot Chili Peppers	ROCK
Let It Be	The Beatles	ROCK

Poison	Alice Cooper	ROCK
Imagine	John Lennon	ROCK
The Passenger	Iggy Pop	ROCK
So What	Miles Davis	JAZZ
What a Wonderful World	Louis Armstrong	JAZZ
Take Five	The Dave Brubeck Quartet	JAZZ
Take Five	Dave Brubeck	JAZZ
Don't Know Why	Norah Jones	JAZZ
Feeling Good	Nina Simone	JAZZ
Rehab	Amy Winehouse	JAZZ
Blue in Green	Miles Davis	JAZZ
Hit the Road Jack	Ray Charles	JAZZ
Back to Black	Amy Winehouse	JAZZ
Come Away with Me	Norah Jones	JAZZ
All Blues	Miles Davis	JAZZ
My Baby Just Cares for Me	Nina Simone	JAZZ
You Know I'm No Good	Amy Winehouse	JAZZ
Freddie Freeloader	Miles Davis	JAZZ
Fever	Peggy Lee	JAZZ
Blue Train	John Coltrane	JAZZ
Flamenco Sketches	Miles Davis	JAZZ
Sunrise	Norah Jones	JAZZ
Cantaloupe Island	Herbie Hancock	JAZZ
Feeling Good	Michael Bublé	JAZZ
Watermelon Man	Herbie Hancock	JAZZ
Dance Me To The End Of Love	Madeleine Peyroux	JAZZ
My Favorite Things	John Coltrane	JAZZ
Sinnerman	Nina Simone	JAZZ
Turn Me On	Norah Jones	JAZZ
I Put a Spell on You	Nina Simone	JAZZ
Cry Me a River	Julie London	JAZZ
In the Mood	Glenn Miller	JAZZ
Fly Me to the Moon	Frank Sinatra	JAZZ
At Last	Etta James	JAZZ
Beat Tick Music (Live)	G.M.Orchestra	JAZZ
My Way	Frank Sinatra	JAZZ
La vie en rose	Louis Armstrong	JAZZ
Giant Steps	John Coltrane	JAZZ
Autumn Leaves	Cannonball Adderley	JAZZ
Unforgettable	Nat King Cole	JAZZ
'Round Midnight	Thelonious Monk	JAZZ
Tears Dry on Their Own	Amy Winehouse	JAZZ
The Look Of Love	Diana Krall	JAZZ

Smooth Operator	Sade	JAZZ
Mack the Knife	Louis Armstrong	JAZZ
My Funny Valentine	Chet Baker	JAZZ
We Are Free (Live)	G.M.Orchestra	JAZZ
Chameleon	Herbie Hancock	JAZZ
Georgia On My Mind	Ray Charles	JAZZ
Home	Michael Bublé	JAZZ
Love Me or Leave Me	Nina Simone	JAZZ
I've Got to See You Again	Norah Jones	JAZZ
I've Got You Under My Skin	Frank Sinatra	JAZZ
Naima	John Coltrane	JAZZ
Moanin'	Art Blakey & The Jazz Messengers	JAZZ
Strange Fruit	Billie Holiday	JAZZ
Let's Fall In Love	Diana Krall	JAZZ
Don't Wait Too Long	Madeleine Peyroux	JAZZ
I've Got You Under My Skin	Diana Krall	JAZZ
Strangers in the Night	Frank Sinatra	JAZZ
Love Is a Losing Game	Amy Winehouse	JAZZ
Worrisome Heart	Melody Gardot	JAZZ
A Kiss to Build a Dream On	Louis Armstrong	JAZZ
Song For My Father	Horace Silver	JAZZ
Moondance	Van Morrison	JAZZ
Nine Million Bicycles	Katie Melua	JAZZ
Shoot the Moon	Norah Jones	JAZZ
Feelin' the Same Way	Norah Jones	JAZZ
Summertime	Ella Fitzgerald	JAZZ
Seven Years	Norah Jones	JAZZ
Erotic Wonderland	SexyPhone	JAZZ
Cold Cold Heart	Norah Jones	JAZZ
Put Your Records On	Corinne Bailey Rae	JAZZ
Maiden Voyage	Herbie Hancock	JAZZ
L-O-V-E	Nat King Cole	JAZZ
SexyPhone Tamboris Romantico I - (Live)	SexyPhone	JAZZ
Everything	Michael Bublé	JAZZ
Rose Rouge	St. Germain	JAZZ
Goodbye Pork Pie Hat	Charles Mingus	JAZZ
The Sidewinder	Lee Morgan	JAZZ
Sweet About Me	Gabriella Cilmi	JAZZ
Mad About the Boy	Dinah Washington	JAZZ
Lonestar	Norah Jones	JAZZ
Koop Island Blues	Koop	JAZZ
God Bless The Child	Billie Holiday	JAZZ

Blame It on My Youth	Brad Mehldau	JAZZ
St. Thomas	Sonny Rollins	JAZZ
Don't Cry Baby	Madeleine Peyroux	JAZZ
Minnie the Moocher	Cab Calloway	JAZZ
Don't Let Me Be Misunderstood	Nina Simone	JAZZ
Someone To Watch Over Me	Ella Fitzgerald	JAZZ
The Nearness of You	Norah Jones	JAZZ
Birdland	Weather Report	JAZZ
Save the Last Dance for Me	Michael Bublé	JAZZ
Rhapsody in Blue	George Gershwin	JAZZ
Summertime	Miles Davis	JAZZ
Like a Star	Corinne Bailey Rae	JAZZ
Temptation	Diana Krall	JAZZ
One Flight Down	Norah Jones	JAZZ
Move	Miles Davis	JAZZ
Twentysomething	Jamie Cullum	JAZZ
Just Friends	Amy Winehouse	JAZZ
Wake Up Alone	Amy Winehouse	JAZZ
Flamenco Sketches (Alternate Take)	Miles Davis	JAZZ
Between The Bars	Madeleine Peyroux	JAZZ
Minor Swing	Django Reinhardt	JAZZ
Blue Rondo a La Turk	The Dave Brubeck Quartet	JAZZ
Those Sweet Words	Norah Jones	JAZZ
The Girl From Ipanema	Stan Getz	JAZZ
SexyPhone (Live)	SexyPhone	JAZZ
The Closest Thing to Crazy	Katie Melua	JAZZ
Painter Song	Norah Jones	JAZZ
One Yaer Sax Power Symphony (Live)	Orchestra de Blonde	JAZZ
Blue Monk	Thelonious Monk	JAZZ
Hello Dolly	Louis Armstrong	JAZZ
J'Ai Deux Amours	Madeleine Peyroux	JAZZ
Spider's Web	Katie Melua	JAZZ
Blue Moon	Billie Holiday	JAZZ
Cry Me A River	Diana Krall	JAZZ
Come To Me	Koop	JAZZ
Straight, No Chaser	Thelonious Monk	JAZZ
Come Fly With Me	Frank Sinatra	JAZZ
Bitches Brew	Miles Davis	JAZZ
Get Your Way	Jamie Cullum	JAZZ
Nightingale	Norah Jones	JAZZ
Caravan	Duke Ellington	JAZZ
Summertime	Sarah Vaughan	JAZZ
'Round Midnight	Miles Davis	JAZZ

New York, New York	Frank Sinatra	JAZZ
Unchain My Heart	Ray Charles	JAZZ
Valerie	Amy Winehouse	JAZZ
Sway	Dean Martin	JAZZ
Fables of Faubus	Charles Mingus	JAZZ
The Long Day Is Over	Norah Jones	JAZZ
He Can Only Hold Her	Amy Winehouse	JAZZ
You Don't Know Me	Michael Bublé	JAZZ
Ornithology	Charlie Parker	JAZZ
Moonlight Serenade	Glenn Miller	JAZZ
Beyond the Sea	Bobby Darin	JAZZ
All Of Me	Billie Holiday	JAZZ
Boogie Stop Shuffle	Charles Mingus	JAZZ
OAM's Blues	Aaron Goldberg	JAZZ
Mack the Knife	Bobby Darin	JAZZ
East Of The Sun (And West Of The Moon)	Diana Krall	JAZZ
Cousin Mary	John Coltrane	JAZZ
No Ordinary Love	Sade	JAZZ
Syedda's Song Flute	John Coltrane	JAZZ
It's Oh So Quiet	Björk	JAZZ
I'm Old Fashioned	John Coltrane	JAZZ
These Are The Days	Jamie Cullum	JAZZ
Three to Get Ready	The Dave Brubeck Quartet	JAZZ
Soul Bossa Nova	Quincy Jones	JAZZ
Jeru	Miles Davis	JAZZ
Moonlight Sonata	Ludwig van Beethoven	Música Clássica
Clair de lune	Claude Debussy	Música Clássica
Air	Johann Sebastian Bach	Música Clássica
Bolero	Maurice Ravel	Música Clássica
Adagio For Strings	Samuel Barber	Música Clássica
Requiem	Wolfgang Amadeus Mozart	Música Clássica
Hungarian Dance No. 5	Johannes Brahms	Música Clássica
Ave Maria	Franz Schubert	Música Clássica
Für Elise	Ludwig van Beethoven	Música Clássica
Canon	Johann Pachelbel	Música Clássica
The Blue Danube	Johann Strauss II	Música Clássica

In the Hall of the Mountain King	Edvard Grieg	Música Clássica
O Fortuna	Carl Orff	Música Clássica
Ride of the Valkyries	Richard Wagner	Música Clássica
Eine kleine Nachtmusik	Wolfgang Amadeus Mozart	Música Clássica
Toccatà and Fugue in D Minor	Johann Sebastian Bach	Música Clássica
Spring	Antonio Vivaldi	Música Clássica
Adagio in G minor	Tomaso Giovanni Albinoni	Música Clássica
1812 Overture	Pyotr Ilyich Tchaikovsky	Música Clássica
Lacrimosa	Wolfgang Amadeus Mozart	Música Clássica
Nocturne in C# minor	Frédéric Chopin	Música Clássica
Rhapsody in Blue	George Gershwin	Música Clássica
Ode to Joy	Ludwig van Beethoven	Música Clássica
Waltz of the Flowers	Pyotr Ilyich Tchaikovsky	Música Clássica
Pavane	Gabriel Fauré	Música Clássica
Jesu, Joy Of Man's Desiring	Johann Sebastian Bach	Música Clássica
Flower Duet	Léo Delibes	Música Clássica
Die vier Jahreszeiten	Antonio Vivaldi	Música Clássica
Morning	Edvard Grieg	Música Clássica
Spiegel im Spiegel	Arvo Pärt	Música Clássica
Finlandia	Jean Sibelius	Música Clássica
Dance of the Knights	Sergei Prokofiev	Música Clássica
Notturmo	Giacomo Cataldo	Música Clássica
Peer Gynt - Suite No.1	Edvard Grieg	Música Clássica
Piccola reminiscenza	Giacomo Cataldo	Música Clássica
Fantasia	Giacomo Cataldo	Música Clássica
Molto vivace	Ludwig van Beethoven	Música Clássica
Allegro	Antonio Vivaldi	Música Clássica
Leggenda	Giacomo Cataldo	Música Clássica

Aquarium	Camille Saint-Saëns	Música Clássica
Gnossienne No. 1	Erik Satie	Música Clássica
Danse Macabre	Camille Saint-Saëns	Música Clássica
Hungarian Rhapsody No. 2	Franz Liszt	Música Clássica
Symphonie #3 Op. 90: Poco Alle	Johannes Brahms	Música Clássica
Sospiro elaborato	Giacomo Cataldo	Música Clássica
Gymnopedie No. 1	Erik Satie	Música Clássica
Preludio sinfônico	Giacomo Cataldo	Música Clássica
Minute Waltz	Frédéric Chopin	Música Clássica
Allegro con fuoco	Antonín Dvořák	Música Clássica
Minuet	Luigi Boccherini	Música Clássica
The Moldau	Bedřich Smetana	Música Clássica
The Swan	Camille Saint-Saëns	Música Clássica
Morning Mood	Edvard Grieg	Música Clássica
Dies Irae	Wolfgang Amadeus Mozart	Música Clássica
Dance of the Sugar Plum Fairy	Pyotr Ilyich Tchaikovsky	Música Clássica
The Lark Ascending	Ralph Vaughan Williams	Música Clássica
Arrival of the Queen of Sheba	Georg Friedrich Händel	Música Clássica
Allegro ma non tanto	Sergei Rachmaninoff	Música Clássica
Symphony 99 In Eb/Vivace	Franz Joseph Haydn	Música Clássica
Fantasia on Greensleeves	Ralph Vaughan Williams	Música Clássica
Carmen - March of the Toreador	Georges Bizet	Música Clássica
Badinerie	Johann Sebastian Bach	Música Clássica
Largo	Antonín Dvořák	Música Clássica
La Campanella	Franz Liszt	Música Clássica
Allegro con brio	Ludwig van Beethoven	Música Clássica
Spring Song	Felix Mendelssohn	Música Clássica
Humoresque	Antonín Dvořák	Música Clássica

Primavera	Ludovico Einaudi	Música Clássica
On the Nature of Daylight	Max Richter	Música Clássica
Suite No. 4 In D Minor	Georg Friedrich Händel	Música Clássica
Divenire	Ludovico Einaudi	Música Clássica
Impromptu No. 3 in G flat major	Franz Schubert	Música Clássica
Pathetique Movement	Ludwig van Beethoven	Música Clássica
Nimrod	Sir Edward Elgar	Música Clássica
Ballade No. 1 in G minor, Op. 23	Frédéric Chopin	Música Clássica
Russian Dance	Pyotr Ilyich Tchaikovsky	Música Clássica
Con Te Partiro	Andrea Bocelli	Música Clássica
Prelude in E Minor, Op. 28, No. 4	Frédéric Chopin	Música Clássica
Funeral March	Frédéric Chopin	Música Clássica
Allegro	Johann Sebastian Bach	Música Clássica
Anitra's Dance	Edvard Grieg	Música Clássica
Liebestraum	Franz Liszt	Música Clássica
Adagietto	Gustav Mahler	Música Clássica
Reverie	Claude Debussy	Música Clássica
Adagio molto e cantabile	Ludwig van Beethoven	Música Clássica
Sabre Dance	Արամ Խաչատրյան	Música Clássica
Chi mai	Ennio Morricone	Música Clássica
Symphony No. 9 (Scherzo)	Ludwig van Beethoven	Música Clássica
Grey Clouds	Franz Liszt	Música Clássica
Moments Musicaux, D780 N 3 en Fa Mineur	Franz Schubert	Música Clássica
Symphony No. 9 in E minor; 4th movement; Allegro con fuoco	Antonín Dvořák	Música Clássica
Rondo alla Turca	Wolfgang Amadeus Mozart	Música Clássica
Ardens Est Cor Meum	Giacomo Cataldo	Música Clássica
Traumerei	Robert Schumann	Música Clássica
Pavane pour une infante defunte	Maurice Ravel	Música Clássica



Fanfare for the Common Man	Aaron Copland	Música Clássica
Cradle Song	Johannes Brahms	Música Clássica
Largo	Antonio Vivaldi	Música Clássica
Presto	Antonio Vivaldi	Música Clássica
Solveig's Song	Edvard Grieg	Música Clássica
Allegro	Wolfgang Amadeus Mozart	Música Clássica
Die Fledermaus Overture	Johann Strauss II	Música Clássica
Symphony No.5 in C sharp minor (Adagietto) {15}	Gustav Mahler	Música Clássica
Valse triste	Jean Sibelius	Música Clássica
Symphony Nr.2	Sergei Rachmaninoff	Música Clássica
The Barber of Seville	Gioacchino Rossini	Música Clássica
Hallelujah Chorus	Georg Friedrich Händel	Música Clássica
Mars, the Bringer of War	Gustav Holst	Música Clássica
Allegro molto appassionato	Felix Mendelssohn	Música Clássica
Habanera	Georges Bizet	Música Clássica
Meditation from Thais	Jules Massenet	Música Clássica
Piano Concerto No.2 in C minor (1st Movement) {2}	Sergei Rachmaninoff	Música Clássica
River Flows in You	Yiruma	Música Clássica
Vltava	Bedřich Smetana	Música Clássica
O mio babbino caro	Giacomo Puccini	Música Clássica
Benedictus	Wolfgang Amadeus Mozart	Música Clássica
Adagio For Organ & Strings	Tomaso Giovanni Albinoni	Música Clássica
Adagio for Strings, Op. 11	Samuel Barber	Música Clássica
Vltava - Die Moldau	Bedřich Smetana	Música Clássica
Symphony 103 In Eb 'drum Roll'/Allegro Con Spirito	Franz Joseph Haydn	Música Clássica
Gnossienne No. 4	Erik Satie	Música Clássica
Sur le fil	Yann Tiersen	Música Clássica
Symphony 100 In G 'military'/Minuet (Moderato) & Trio	Franz Joseph Haydn	Música Clássica

Storm	Vanessa-Mae	Música Clássica
Adagio g-moll	Tomaso Giovanni Albinoni	Música Clássica
Dies irae	Giuseppe Verdi	Música Clássica
Concerning Hobbits	Howard Shore	Música Clássica
Agnus Dei	Wolfgang Amadeus Mozart	Música Clássica
Toccatà and Fugue in D Minor	Vanessa-Mae	Música Clássica
Now We Are Free	Hans Zimmer	Música Clássica
Rex Tremendae	Wolfgang Amadeus Mozart	Música Clássica
Night on the Bare Mountain	Modest Mussorgsky Petrovich	Música Clássica
Cantique de Jean Racine	Gabriel Fauré	Música Clássica
Feierlich und gemessen, ohne zu schleppen	Gustav Mahler	Música Clássica
Song Without Words	Felix Mendelssohn	Música Clássica
Adagio For Strings {6}	Samuel Barber	Música Clássica
Je te veux	Erik Satie	Música Clássica
Nessun dorma	Paul Potts	Música Clássica
G VII	Johannes Brahms	Música Clássica
Wesendonk Lieder: Schmerzen	Richard Wagner	Música Clássica
Allegro non molto	Antonio Vivaldi	Música Clássica
The Heart Asks Pleasure First	Michael Nyman	Música Clássica
Adiemus	Adiemus	Música Clássica
Metamorphosis One	Philip Glass	Música Clássica
Largo	Georg Friedrich Händel	Música Clássica
Dance Of The Mirlitons	Pyotr Ilyich Tchaikovsky	Música Clássica
Sanctus	Wolfgang Amadeus Mozart	Música Clássica
No. 3 in D flat major, "Un Sospiro"	Franz Liszt	Música Clássica
Metamorphosis Two	Philip Glass	Música Clássica
Nessun dorma	Giacomo Puccini	Música Clássica
Como Nossos Pais	Elis Regina	MPB
Cotidiano	Chico Buarque	MPB

Samba da bênção	Vinicius de Moraes	MPB
Amado	Vanessa da Mata	MPB
Salão de Beleza	Zeca Baleiro	MPB
Beija Eu	Marisa Monte	MPB
Aquarela	Toquinho	MPB
Admiração	Paulinho Moska	MPB
Telegrama	Zeca Baleiro	MPB
Oceano	Djavan	MPB
Vambora	Adriana Calcanhotto	MPB
Essas Emoções	Zeca Baleiro	MPB
Amor I Love You	Marisa Monte	MPB
Madalena	Elis Regina	MPB
Quando a Chuva Passar	Ivete Sangalo	MPB
Infinito Particular	Marisa Monte	MPB
Brasil Pandeiro	Novos Baianos	MPB
Esquadros	Adriana Calcanhotto	MPB
Paciência	Lenine	MPB
Faz Parte Do Meu Show	Cazuza	MPB
Pés Cansados	Sandy Leah	MPB
João E Maria	Chico Buarque	MPB
Ainda Lembro	Marisa Monte	MPB
Bem Que Se Quis	Marisa Monte	MPB
Pra Ser Sincero	Marisa Monte	MPB
Fico Assim Sem Você	Adriana Calcanhotto	MPB
Fato Consumado	Djavan	MPB
Vilarejo	Marisa Monte	MPB
Velha Infância	Tribalistas	MPB
Hoje Eu Quero Sair Só	Lenine	MPB
O anjo mais velho	O Teatro Mágico	MPB
A Banda	Chico Buarque	MPB
O Que Me Importa	Marisa Monte	MPB
Alegria, Alegria	Caetano Veloso	MPB
Não Me Deixe Só	Vanessa da Mata	MPB
Sem Jeito	Sandy Leah	MPB
Último Romance	Los Hermanos	MPB
Meu Caro Amigo	Chico Buarque	MPB
Vai Passar	Chico Buarque	MPB
Ela/Ele	Sandy Leah	MPB
Preciso Me Encontrar	Cartola	MPB
O Segundo Sol	Cássia Eller	MPB
O Vencedor	Los Hermanos	MPB
Sentimental	Los Hermanos	MPB
Domingo No Parque	Gilberto Gil	MPB

Mentiras	Adriana Calcanhotto	MPB
O Bonde do Dom	Marisa Monte	MPB
Tão Comum	Sandy Leah	MPB
Mais Alguém	Roberta Sá	MPB
Todo Carnaval Tem Seu Fim	Los Hermanos	MPB
Eu Te Devoro	Djavan	MPB
Perdida e Salva	Sandy Leah	MPB
Bala Com Bala	Elis Regina	MPB
Já Sei Namorar	Tribalistas	MPB
Construção	Chico Buarque	MPB
Azul Da Cor Do Mar	Tim Maia	MPB
Maresia	Adriana Calcanhotto	MPB
Valsinha	Chico Buarque	MPB
O Vento	Los Hermanos	MPB
Segue o Seco	Marisa Monte	MPB
Apesar de você	Chico Buarque	MPB
Metamorfose Ambulante	Raul Seixas	MPB
Samba De Orly	Chico Buarque	MPB
águas de março	Elis Regina	MPB
Por Onde Andei	Nando Reis	MPB
O Leãozinho	Caetano Veloso	MPB
Casa No Campo	Elis Regina	MPB
A Festa	Maria Rita	MPB
Sampa	Caetano Veloso	MPB
Jack Soul Brasileiro	Lenine	MPB
Por Enquanto	Cássia Eller	MPB
Segredo	Sandy Leah	MPB
Lenda	Céu	MPB
Sina	Djavan	MPB
Malandragem	Cássia Eller	MPB
Garganta	Ana Carolina	MPB
Mais Feliz	Adriana Calcanhotto	MPB
Take It Easy My Brother Charles	Jorge Ben	MPB
Alô Fevereiro	Roberta Sá	MPB
Mais um Rosto	Sandy Leah	MPB
Baby	Os Mutantes	MPB
Preta Pretinha	Novos Baianos	MPB
Bem Leve	Marisa Monte	MPB
Cara Valente	Maria Rita	MPB
Malemolência	Céu	MPB
Retrato Pra Iaiá	Los Hermanos	MPB
aLÉm do que se vê	Los Hermanos	MPB
Na Estrada	Marisa Monte	MPB

Dedilhada	Sandy Leah	MPB
Casa	Sandy Leah	MPB
Saudade	Sandy Leah	MPB
Carolina	Seu Jorge	MPB
Roda viva	Chico Buarque	MPB
Deus Lhe Pague	Chico Buarque	MPB
Como Eu Quero (Acústico)	Kid Abelha	MPB
Acabou Chorare	Novos Baianos	MPB
Queixa	Caetano Veloso	MPB
Travessia	Milton Nascimento	MPB
All Star	Nando Reis	MPB
E.C.T.	Cássia Eller	MPB
Tempo	Sandy Leah	MPB
Panis Et Circenses	Marisa Monte	MPB
Exagerado	Cazuza	MPB
Palavras Ao Vento	Cássia Eller	MPB
Se	Djavan	MPB
Ainda Bem	Vanessa da Mata	MPB
Tropicália	Caetano Veloso	MPB
Morena	Los Hermanos	MPB
Quem Eu Sou	Sandy Leah	MPB
Esconderijo	Sandy Leah	MPB
Dias Iguais (part. Nerina Pallot)	Sandy Leah	MPB
Aquela dos 30	Sandy Leah	MPB
Olhos Meus	Sandy Leah	MPB
O Samba da minha terra	Novos Baianos	MPB
Tatuagem	Chico Buarque	MPB
Dança De Solidao	Beth Carvalho	MPB
Encontros E Despedidas	Maria Rita	MPB
Quem Te Viu, Quem Te Vê	Chico Buarque	MPB
O Barquinho	Nara Leão	MPB
Romaria	Elis Regina	MPB
Vá Morar Com O Diabo	Cássia Eller	MPB
Odara	Caetano Veloso	MPB
Samba Do Approach	Zeca Baleiro	MPB
Metade	Adriana Calcanhotto	MPB
Pavão Mysteriozo (Live)	Fernanda Takai	MPB
Escolho Você	Sandy Leah	MPB
Desalento	Chico Buarque	MPB
Sangue Latino	Secos & Molhados	MPB
Partido Alto	Cássia Eller	MPB
Nem um Dia	Djavan	MPB
Negue	Maria Bethânia	MPB

Vermelho	Vanessa da Mata	MPB
Para Ver as Meninas	Marisa Monte	MPB
Olhos Nos Olhos	Chico Buarque	MPB
Ao Meu Redor	Marisa Monte	MPB
Samba de roda	Maria Bethânia	MPB
Monalisa	Jorge Vercilo	MPB
Devolva-me	Adriana Calcanhotto	MPB
A Rede	Lenine	MPB
Chão de Giz	Zé Ramalho	MPB
Agora Eu Já Sei	Ivete Sangalo	MPB
Sim	Sandy Leah	MPB
Refúgio	Sandy Leah	MPB
Morada	Sandy Leah	MPB
Alvorada	Cartola	MPB
Irene	Caetano Veloso	MPB
Gentileza	Marisa Monte	MPB
A Flor	Los Hermanos	MPB
Todo Amor Que Houver Nessa Vida	Cássia Eller	MPB
Carnavália	Tribalistas	MPB
Preciso Me Encontrar	Cartola	SAMBA
Samba da bênção	Vinicius de Moraes	SAMBA
Alvorada	Cartola	SAMBA
Dança De Solidao	Beth Carvalho	SAMBA
Cotidiano	Chico Buarque	SAMBA
Brasil Pandeiro	Novos Baianos	SAMBA
Alô Fevereiro	Roberta Sá	SAMBA
Mas Que Nada	Elza Soares	SAMBA
Cabide	Mart'nália	SAMBA
E A Vida Continua	Paulinho Da Viola	SAMBA
Carolina	Seu Jorge	SAMBA
Samba a Dois	Los Hermanos	SAMBA
Mas Que Nada	Jorge Ben	SAMBA
Preto, Cor Preta	Jorge Aragão	SAMBA
Mas Que Nada	Tamba Trio	SAMBA
O Samba da minha terra	Novos Baianos	SAMBA
Samba de Janeiro	Bellini	SAMBA
Timoneiro	Paulinho Da Viola	SAMBA
Vá Morar Com O Diabo	Cássia Eller	SAMBA
Samba Do Approach	Zeca Baleiro	SAMBA
Magalenha	Sérgio Mendes	SAMBA
Samba De Um Minuto	Roberta Sá	SAMBA
Mais Alguém	Roberta Sá	SAMBA
Não Me Deixe Só	Vanessa da Mata	SAMBA

Vai Passar	Chico Buarque	SAMBA
Minha	Cartola	SAMBA
O Mar Serenou	Clara Nunes	SAMBA
Vou Festejar	Beth Carvalho	SAMBA
A Semente	Bezerra da Silva	SAMBA
O Telefone Tocou Novamente	Jorge Ben	SAMBA
Ramiro's Theme	Buscemi	SAMBA
Mas que nada	Sérgio Mendes	SAMBA
Samba de roda	Maria Bethânia	SAMBA
Burguesinha	Seu Jorge	SAMBA
Aquele Abraço	Gilberto Gil	SAMBA
Chega	Mart'nália	SAMBA
Did It Again	Shakira	SAMBA
Take It Easy My Brother Charles	Jorge Ben	SAMBA
Sambassim	Fernanda Porto	SAMBA
Trem das Onze	Demônios Da Garoa	SAMBA
Saudosa Maloca	Adoniran Barbosa	SAMBA
Guardei Minha Viola	Paulinho Da Viola	SAMBA
O mundo é um moinho	Cartola	SAMBA
Tive Sim	Cartola	SAMBA
Mas que nada	Sérgio Mendes & Brasil '66	SAMBA
Alegria	Cartola	SAMBA
Mas que nada	Sérgio Mendes	SAMBA
Samba De Orly	Chico Buarque	SAMBA
Laranjeira	Roberta Sá	SAMBA
Boto Meu Povo Na Rua	Mart'nália	SAMBA
Desafinado	Stan Getz	SAMBA
é luxo só	Rosa Passos	SAMBA
Deixa A Vida Me Levar	Zeca Pagodinho	SAMBA
Apesar de você	Chico Buarque	SAMBA
As Rosas Não Falam	Cartola	SAMBA
Admiração	Paulinho Moska	SAMBA
Foi um Rio Que Passou Em Minha Vida	Paulinho Da Viola	SAMBA
Homenagem Ao Malandro	Chico Buarque	SAMBA
Samba na Sola	Céu	SAMBA
Verdade	Zeca Pagodinho	SAMBA
Samba Italiano	Adoniran Barbosa	SAMBA
Caxambu	Almir Guineto	SAMBA
Pecado Capital	Paulinho Da Viola	SAMBA
Tinindo Trincando	Novos Baianos	SAMBA
Morena De Angola	Clara Nunes	SAMBA
Preta Pretinha	Novos Baianos	SAMBA
Swing de Campo Grande	Novos Baianos	SAMBA

Sonho Meu	Maria Bethânia	SAMBA
Coração Leviano	Clara Nunes	SAMBA
Maracangalha	Dorival Caymmi	SAMBA
Trem das Onze	Adoniran Barbosa	SAMBA
Convite Para A Vida	Seu Jorge	SAMBA
Pé do meu samba	Mart'nália	SAMBA
Ordenes E Farei	Cartola	SAMBA
Conto De Areia	Clara Nunes	SAMBA
Defunto Caguite	Bezerra da Silva	SAMBA
Kickin' Samba	Soulstance	SAMBA
Nem Vem Que Nao Tem	Wilson Simonal	SAMBA
A Banda	Chico Buarque	SAMBA
Construção	Chico Buarque	SAMBA
Com qualquer dois mil réis	Novos Baianos	SAMBA
Samba de amor e ódio	Roberta Sá	SAMBA
Samba Do Grande Amor	Chico Buarque	SAMBA
Chiclete Com Banana	Gilberto Gil	SAMBA
Tive Sim	Luiz Melodia	SAMBA
Sim	Cartola	SAMBA
Disritmia	Martinho Da Vila	SAMBA
Medley: Nao Quero Mais Saber Dela/So Pra Contrariar	Arlindo Cruz	SAMBA
Deixa O Verão	Mariana Aydar	SAMBA
Não Deixe O Samba Morrer	Alcione	SAMBA
One Note Samba	Astrud Gilberto	SAMBA
Argumento	Paulinho Da Viola	SAMBA
Nordeste:Seu Povo,Seu Canto E Sua Gloria	Nara Leão	SAMBA
Peito Vazio	Cartola	SAMBA
Batuque na Cozinha	Martinho Da Vila	SAMBA
Expressão Do Teu Olhar	Candeia	SAMBA
Pranto De Poeta	Cartola	SAMBA
Carolina Carol Bela	Jorge Ben	SAMBA
Canto De Nanã	Dorival Caymmi	SAMBA
O Bonde do Dom	Marisa Monte	SAMBA
João E Maria	Chico Buarque	SAMBA
Caviar	Zeca Pagodinho	SAMBA
Candomblé	Mariana Aydar	SAMBA
Seu Balancê	Zeca Pagodinho	SAMBA
Tão Comum (part. Seu Jorge)	Sandy Leah	SAMBA
Quem Te Viu, Quem Te Vê	Chico Buarque	SAMBA
Coisquinha Do Pai (Ao Vivo)	Jorge Aragão	SAMBA
A Menina Dança	Novos Baianos	SAMBA
Acontece	Cartola	SAMBA



Malandragem dá um Tempo	Bezerra da Silva	SAMBA
Linha De Passe	João Bosco	SAMBA
Feijoada Completa	Chico Buarque	SAMBA
So Danço Samba (I Only Dance Samba)	Wanda Sá	SAMBA
Janeiros	Roberta Sá	SAMBA
Cobra Criada	João Bosco	SAMBA
Lá Vem a Baiana	Jussara Silveira	SAMBA
South American Way	Carmen Miranda	SAMBA
Samba de Orly	Tania Maria	SAMBA
Tempos Idos	Cartola	SAMBA
Carnaval	Santana	SAMBA
Mã	Tom Zé	SAMBA
Com A Perna No Mundo	Gonzaguinha	SAMBA
Cria	Maria Rita	SAMBA
Eu Canto Samba	Paulinho Da Viola	SAMBA
Menino Das Laranjas	Mariana Aydar	SAMBA
Partido alto	Mônica Salmaso	SAMBA
Alegria	Vanessa da Mata	SAMBA
Tá Perdoado	Maria Rita	SAMBA
Quatro Paredes	Marisa Monte	SAMBA
Matador	Los Fabulosos Cadillacs	SAMBA
Para Ver as Meninas	Marisa Monte	SAMBA
A Rita	Chico Buarque	SAMBA
Aquarela Do Brasil	Gal Costa	SAMBA
O Homem Falou	Maria Rita	SAMBA
Verde Que Te Quero Rosa	Cartola	SAMBA
La Bomba	King Africa	SAMBA
O Rei Pele	Jackson do Pandeiro	SAMBA
Cantinho Escondido	Marisa Monte	SAMBA
Besta é Tu	Novos Baianos	SAMBA
Samba	Faze Action	SAMBA
Canto Das Tres Racas	Clara Nunes	SAMBA
Meu ébano	Alcione	SAMBA
Samba de Uma Nota So	Stan Getz & Charlie Byrd	SAMBA
Escurinha	Cartola	SAMBA
Xica Da Silva	Jorge Ben	SAMBA
Sufrimento De Quem Ama	Clara Nunes	SAMBA
Samba Sensitive	Oscar Peterson	SAMBA
A Flor e o Espinho	Nelson Cavaquinho	SAMBA
Bicho Feroz	Bezerra da Silva	SAMBA
Na Gangorra	Mariana Aydar	SAMBA
The Gentle Rain	Mary Juane Clair	POP
Billie Jean	Michael Jackson	POP

Poker Face	Lady Gaga	POP
Say It Right	Nelly Furtado	POP
I Kissed a Girl	Katy Perry	POP
Beat It	Michael Jackson	POP
Thriller	Michael Jackson	POP
Torn	Natalie Imbruglia	POP
Take on Me	a-ha	POP
Bad Romance	Lady Gaga	POP
Hung Up	Madonna	POP
Hot n Cold	Katy Perry	POP
Bleeding Love	Leona Lewis	POP
Paparazzi	Lady Gaga	POP
Grace Kelly	Mika	POP
Just Dance	Lady Gaga	POP
Maneater	Nelly Furtado	POP
Time After Time	Cyndi Lauper	POP
Toxic	Britney Spears	POP
Smile	Lily Allen	POP
Can't Get You Out of My Head	Kylie Minogue	POP
White Flag	Dido	POP
Because of You	Kelly Clarkson	POP
Lovefool	The Cardigans	POP
Disturbia	Rihanna	POP
This Is the Life	Amy Macdonald	POP
She Will Be Loved	Maroon 5	POP
Mercy	Duffy	POP
Kiss Me	Sixpence None the Richer	POP
Womanizer	Britney Spears	POP
Don't Stop the Music	Rihanna	POP
Bad Day	Daniel Powter	POP
You're Beautiful	James Blunt	POP
Here with Me	Dido	POP
Dancing Queen	ABBA	POP
This Love	Maroon 5	POP
TiK ToK	Ke\$ha	POP
Smooth Criminal	Michael Jackson	POP
Unwritten	Natasha Bedingfield	POP
Alejandro	Lady Gaga	POP
Thank You	Dido	POP
Cry Me a River	Justin Timberlake	POP
Black or White	Michael Jackson	POP
Like a Prayer	Madonna	POP
Don't Speak	No Doubt	POP

Hollaback Girl	Gwen Stefani	POP
Angels	Robbie Williams	POP
Love Song	Sara Bareilles	POP
Frozen	Madonna	POP
SexyBack	Justin Timberlake	POP
I Gotta Feeling	Black Eyed Peas	POP
Breakaway	Kelly Clarkson	POP
Suddenly I See	KT Tunstall	POP
Since U Been Gone	Kelly Clarkson	POP
Ain't No Other Man	Christina Aguilera	POP
Beautiful	Christina Aguilera	POP
Bad	Michael Jackson	POP
Candyman	Christina Aguilera	POP
Whenever, Wherever	Shakira	POP
Genie in a Bottle	Christina Aguilera	POP
All Good Things (Come to an End)	Nelly Furtado	POP
Sorry	Madonna	POP
Irreplaceable	Beyoncé	POP
Halo	Beyoncé	POP
Behind These Hazel Eyes	Kelly Clarkson	POP
Hurt	Christina Aguilera	POP
Heaven Is a Place on Earth	Belinda Carlisle	POP
Sweet About Me	Gabriella Cilmi	POP
A Thousand Miles	Vanessa Carlton	POP
That's Not My Name	The Ting Tings	POP
The Way You Make Me Feel	Michael Jackson	POP
Unfaithful	Rihanna	POP
Man in the Mirror	Michael Jackson	POP
She Wolf	Shakira	POP
Everybody Wants to Rule the World	Tears for Fears	POP
Mamma Mia	ABBA	POP
Better in Time	Leona Lewis	POP
Feel	Robbie Williams	POP
Believe	Cher	POP
Bubbly	Colbie Caillat	POP
The Fear	Lily Allen	POP
In the Air Tonight	Phil Collins	POP
Complicated	Avril Lavigne	POP
Fireflies	Owl City	POP
Girls Just Want to Have Fun	Cyndi Lauper	POP
Rolling in the Deep	Adele	POP
Gimme More	Britney Spears	POP
Fighter	Christina Aguilera	POP

LDN	Lily Allen	POP
Girlfriend	Avril Lavigne	POP
Take a Chance on Me	ABBA	POP
Material Girl	Madonna	POP
LoveGame	Lady Gaga	POP
Piece of Me	Britney Spears	POP
All That She Wants	Ace of Base	POP
Sweet Dreams (Are Made of This)	Eurythmics	POP
Never Gonna Give You Up	Rick Astley	POP
Teenage Dream	Katy Perry	POP
Goodbye My Lover	James Blunt	POP
All the Things She Said	t.A.T.u.	POP
Ray of Light	Madonna	POP
Heart of Glass	Blondie	POP
Dirty Diana	Michael Jackson	POP
Wanna Be Startin' Somethin'	Michael Jackson	POP
Break the Ice	Britney Spears	POP
Jump	Madonna	POP
Your Song	Elton John	POP
Wind It Up	Gwen Stefani	POP
Cool	Gwen Stefani	POP
Love at First Sight	Kylie Minogue	POP
When I Grow Up	The Pussycat Dolls	POP
La Isla Bonita	Madonna	POP
I'm Like a Bird	Nelly Furtado	POP
Forever Young	Alphaville	POP
Underneath Your Clothes	Shakira	POP
Like a Virgin	Madonna	POP
Don't Stop 'Til You Get Enough	Michael Jackson	POP
Lemon Tree	Fool's Garden	POP
Makes Me Wonder	Maroon 5	POP
Crazy	Gnarls Barkley	POP
Stars Are Blind	Paris Hilton	POP
Every Breath You Take	The Police	POP
Telephone (feat. Beyoncé)	Lady Gaga	POP
Wannabe	Spice Girls	POP
It Must Have Been Love	Roxette	POP
Breathless	The Corrs	POP
Firework	Katy Perry	POP
Eternal Flame	The Bangles	POP
Venus	Bananarama	POP
Turn Off the Light	Nelly Furtado	POP
Tainted Love	Soft Cell	POP

Murder on the Dancefloor	Sophie Ellis-Bextor	POP
Rock Your Body	Justin Timberlake	POP
Down Under	Men at Work	POP
These Words	Natasha Bedingfield	POP
Everytime	Britney Spears	POP
Human Nature	Michael Jackson	POP
Nothing Compares 2 U	Sinéad O'Connor	POP
Fields of Gold	Sting	POP
Rock with You	Michael Jackson	POP
Vogue	Madonna	POP
When You're Gone	Avril Lavigne	POP
Shout	Tears for Fears	POP
Remember the Time	Michael Jackson	POP
Not Fair	Lily Allen	POP
Love Today	Mika	POP
Faith	George Michael	POP
The Winner Takes It All	ABBA	POP
Big Girls Don't Cry	Fergie	POP
4 in the Morning	Gwen Stefani	POP

## APÊNDICE B– TESTES PARA A BASE COM DURAÇÃO ORIGINAL

Base Inteira	
Algoritmo	Cross (10)
RandomForest	52,10
Bagging (RandomForest)	51,62
AdaBoostM1 (RandomForest)	51,24
Bagging (BayesNet)	50,86
BayesNet	50,00
AdaBoostM1(BayesNet)	47,05
Logistic	47,05
AdaBoostM1 (Logistic)	46,38
Bagging (Logistic)	46,38
SimpleLogistic	45,90
NaiveBayes	44,67
libSVM	44,48
SMO	44,48
SimpleCart	44,00
REPTree	42,38
MultilayerPerceptron	41,33
PART	40,67
j48	40,10
DecisionTable	38,67
RandomTree	37,43
IBK	35,62
OneR	34,57
Bagging (NaiveBayes)	44,67

# **APÊNDICE C- TESTES PARA A BASE COM DURAÇÃO DE 30 s**

Base 30 s	
Algoritmo	Cross (10)
RandomForest	48,38
Bagging (RandomForest)	48,05
AdaBoostM1 (RandomForest)	48,00
Bagging (BayesNet)	47,52
BayesNet	46,76
AdaBoostM1(BayesNet)	45,81
Logistic	45,43
AdaBoostM1 (Logistic)	45,24
Bagging (Logistic)	45,24
SimpleLogistic	45,05
NaiveBayes	45,05
libSVM	45,05
SMO	44,57
SimpleCart	44,10
Bagging (NaiveBayes)	43,14
REPTree	41,14
MultilayerPerceptron	41,05
PART	38,29
j48	37,71
DecisionTable	35,43
RandomTree	34,38
IBK	32,67
OneR	31,71

## APÊNDICE D- RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL (BAYES NET)

Base Inteira (7 gêneros)			Base Inteira (5 gêneros)			Base Inteira (MPB x SAMBA)		
Parâmetros	Acertos (%)	ICC	Parâmetros	Acertos (%)	ICC	Parâmetros	Acertos (%)	ICC
Default (SimpleEstimator e K2)	47,05	494	Default (SimpleEstimator e K2)	61,73	463	SimpleEstimator e TAN	63,00	189
<b>SimpleEstimator e TAN</b>	<b>48,19</b>	<b>506</b>	<b>SimpleEstimator e TAN</b>	<b>62,67</b>	<b>470</b>			
SimpleEstimator e TabuSearch	47,05	494	SimpleEstimator e TabuSearch	61,73	463			
SimpleEstimator e HillClimber	47,05	494	SimpleEstimator e HillClimber	61,73	463			
SimpleEstimator e LAGDHillClimber	45,62	479	SimpleEstimator e LAGDHillClimber	60,00	450			
SimpleEstimator e RepeatedHillClimber	47,05	494	SimpleEstimator e RepeatedHillClimber	61,73	463			
BMAEstimator e K2	47,24	496	BMAEstimator e K2	61,73	463			
BMAEstimator e HillClimber	47,24	496	BMAEstimator e HillClimber	61,73	463			
BMAEstimator e RepeatedHillClimber	47,24	496	BMAEstimator e RepeatedHillClimber	61,73	463			



## APÊNDICE E- RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL (KNN)

Base Inteira (7 gêneros)			Base Inteira (5 gêneros)			Base Inteira (MPB x SAMBA)		
Parâmetros	Acertos (%)	ICC	Parâmetros	Acertos (%)	ICC	Parâmetros	Acertos (%)	ICC
Default (K (1))	34,57	363	Default (K (1))	49,33	370	<b>KNN (9)</b>	<b>52,33</b>	<b>157</b>
K (3)	34,95	367	K (3)	46,93	352			
K (5)	36,86	387	K (5)	48,13	361			
K (7)	34,95	367	K (7)	51,60	387			
K (9)	37,05	389	<b>K (9)</b>	<b>53,47</b>	<b>401</b>			
K (11)	38,76	407	K (11)	53,20	399			
K (13)	38,76	407	K (13)	52,27	392			
<b>K (15)</b>	<b>39,43</b>	<b>414</b>	K (15)	52,93	397			

## APÊNDICE F- RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL (SVM)

Base Inteira (7 gêneros)				
Parâmetros		Acertos (%)	ICC	
SVM	Kernel	C		
	Default		13,52	142
C-SVC	Linear	0,1	14,76	155
C-SVC	Linear	0,5	25,71	270
C-SVC	Linear	1	28,00	294
C-SVC	Polynomial	0,1	29,05	305
C-SVC	Polynomial	0,5	29,05	305
C-SVC	Polynomial	1	29,05	305
C-SVC	RBF	0,1	37,33	392
C-SVC	RBF	0,5	40,57	426
C-SVC	RBF	1	40,48	425
C-SVC	Sigmoid	0,1	36,59	387
C-SVC	Sigmoid	0,5	37,14	390
C-SVC	Sigmoid	1	39,81	418

Base Inteira (7 gêneros)				
Parâmetros		Acertos (%)	ICC	
SVM	Kernel	C		
nu-SVC	Linear	0,1	43,81	460
nu-SVC	Linear	0,5	43,81	460
nu-SVC	Linear	1	43,81	460
nu-SVC	Polynomial	0,1	43,43	456
nu-SVC	Polynomial	0,5	43,43	456
nu-SVC	Polynomial	1	43,43	456
nu-SVC	RBF	0,1	44,48	467
nu-SVC	RBF	0,5	44,48	467
nu-SVC	RBF	1	44,48	467
nu-SVC	Sigmoid	0,1	40,29	423
nu-SVC	Sigmoid	0,5	40,29	423
nu-SVC	Sigmoid	1	40,29	423

Base Inteira (5 gêneros)				
Parâmetros		Acertos (%)	ICC	
SVM	Kernel	C		
	Default		56,00	420
C-SVC	Linear	0,1	55,73	418
C-SVC	Linear	0,5	58,13	436
C-SVC	Linear	1	57,60	432
C-SVC	Polynomial	0,1	37,07	278
C-SVC	Polynomial	0,5	37,07	278
C-SVC	Polynomial	1	37,33	280
C-SVC	RBF	0,1	50,27	377
C-SVC	RBF	0,5	55,87	419
C-SVC	RBF	1	56,00	420
C-SVC	Sigmoid	0,1	50,27	377
C-SVC	Sigmoid	0,5	51,87	389
C-SVC	Sigmoid	1	55,73	418

Base Inteira (5 gêneros)				
Parâmetros		Acertos (%)	ICC	
SVM	Kernel	C		
nu-SVC	Linear	0,1	59,07	443
nu-SVC	Linear	0,5	59,07	443
nu-SVC	Linear	1	59,07	443
nu-SVC	Polynomial	0,1	57,60	432
nu-SVC	Polynomial	0,5	57,60	432
nu-SVC	Polynomial	1	57,60	432
nu-SVC	RBF	0,1	58,27	437
nu-SVC	RBF	0,5	58,27	437
nu-SVC	RBF	1	58,27	437
nu-SVC	Sigmoid	0,1	56,80	426
nu-SVC	Sigmoid	0,5	56,80	426
nu-SVC	Sigmoid	1	56,80	426

### Base Inteira (MPB x SAMBA)

#### Parâmetros

nu-SVC (Linear-0,5)	54,00	162
---------------------	-------	-----

## APÊNDICE G- RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL (*BAGGING*)

Base Inteira (7 gêneros)		
Parâmetros	Acertos (%)	ICC
<b>RF (I (800))</b>	<b>52,10</b>	<b>547</b>
SimpleEstimator e TAN	50,86	534
K (15)	39,33	413
nu-SVC (RBF-1)	44,67	469

Base Inteira (5 gêneros)		
Parâmetros	Acertos (%)	ICC
RF (I (600))	65,33	490
<b>SimpleEstimator e TAN</b>	<b>66,53</b>	<b>499</b>
KNN (9)	53,07	398
nu-SVC (Linear-0,5)	61,20	459

Base Inteira (MPB x SAMBA)		
Parâmetros	Acertos (%)	ICC
RF (I (600))	58,00	174
<b>SimpleEstimator e TAN</b>	<b>61,67</b>	<b>185</b>
KNN (9)	53,67	161
nu-SVC (Linear-0,5)	55,67	167

## APÊNDICE H- RESULTADOS PARA A BASE COM DURAÇÃO ORIGINAL (*BOOSTING*)

Base Inteira (7 gêneros)		
Parâmetros	Acertos (%)	ICC
RF (I (800))	50,76	533
SimpleEstimator e TAN	48,19	506
K (15)	39,71	417
nu-SVC (RBF-1)	45,14	474

Base Inteira (5 gêneros)		
Parâmetros	Acertos (%)	ICC
RF (I (600))	64,93	487
SimpleEstimator e TAN	62,40	468
KNN (9)	53,47	401
nu-SVC (Linear-0,5)	59,33	445

Base Inteira (MPB x SAMBA)		
Parâmetros	Acertos (%)	ICC
RF (I (600))	53,00	159
SimpleEstimator e TAN	62,67	188
KNN (9)	52,33	157
nu-SVC (Linear-0,5)	54,00	162

## APÊNDICE I- RESULTADOS PARA A BASE COM DURAÇÃO DE 30 S (BAYES NET)

Base 30 s (7 gêneros)			Base 30 s (5 gêneros)			Base 30 s (MPB x SAMBA)		
Parâmetros	Acertos (%)	ICC	Parâmetros	Acertos (%)	ICC	Parâmetros	Acertos (%)	ICC
Default (SimpleEstimator e K2)	45,05	473	Default (SimpleEstimator e K2)	61,73	463	SimpleEstimator e TAN	60,67	182
<b>SimpleEstimator e TAN</b>	<b>45,43</b>	<b>477</b>	<b>SimpleEstimator e TAN</b>	<b>62,67</b>	<b>470</b>			
SimpleEstimator e TabuSearch	44,86	471	SimpleEstimator e TabuSearch	61,73	463			
SimpleEstimator e HillClimber	45,05	473	SimpleEstimator e HillClimber	61,73	463			
SimpleEstimator e LAGDHillClimber	44,30	465	SimpleEstimator e LAGDHillClimber	60,00	450			
SimpleEstimator e RepeatedHillClimber	45,05	473	SimpleEstimator e RepeatedHillClimber	61,73	463			
BMAEstimator e K2	43,81	460	BMAEstimator e K2	61,73	463			
BMAEstimator e HillClimber	43,81	460	BMAEstimator e HillClimber	61,73	463			
BMAEstimator e RepeatedHillClimber	43,81	460	BMAEstimator e RepeatedHillClimber	61,73	463			
Default (SimpleEstimator e K2)	45,04	473	Default (SimpleEstimator e K2)	61,73	463			

## APÊNDICE J- RESULTADOS PARA A BASE COM DURAÇÃO DE 30 S (KNN)

Base 30 s (7 gêneros)			Base 30 s (5 gêneros)			Base 30 s (MPB x SAMBA)		
Parâmetros	Acertos (%)	ICC	Parâmetros	Acertos (%)	ICC	Parâmetros	Acertos (%)	ICC
<i>Default (K (1))</i>	31,71	333	<i>Default (K (1))</i>	43,33	325	<b>K (13)</b>	<b>57,33</b>	<b>172</b>
K (3)	32,48	341	K (3)	45,33	340			
K (5)	33,24	349	K (5)	48,27	362			
K (7)	34,86	366	K (7)	50,67	380			
K (9)	37,33	392	K (9)	49,60	372			
K (11)	36,95	388	K (11)	49,47	371			
K (13)	38,10	400	<b>K (13)</b>	<b>51,60</b>	<b>387</b>			
<b>K (15)</b>	<b>38,48</b>	<b>404</b>	K (15)	51,20	384			

## APÊNDICE K- RESULTADOS PARA A BASE COM DURAÇÃO DE 30 s (SVM)

Base 30 s (7 gêneros)				
Parâmetros		Acertos (%)	ICC	
SVM	Kernel	C		
	Default		14,10	148
C-SVC	Linear	0,1	43,33	455
C-SVC	Linear	0,5	44,76	470
<b>C-SVC</b>	<b>Linear</b>	<b>1</b>	<b>44,95</b>	<b>472</b>
C-SVC	Polynomial	0,1	27,24	286
C-SVC	Polynomial	0,5	27,24	286
C-SVC	Polynomial	1	27,24	286
C-SVC	RBF	0,1	39,33	413
C-SVC	RBF	0,5	42,48	446
C-SVC	RBF	1	42,76	449
C-SVC	Sigmoid	0,1	39,05	410
C-SVC	Sigmoid	0,5	40,19	422
C-SVC	Sigmoid	1	42,58	447

Base 30 s (7 gêneros)				
Parâmetros		Acertos (%)	ICC	
SVM	Kernel	C		
nu-SVC	Linear	0,1	42,38	445
nu-SVC	Linear	0,5	42,38	445
nu-SVC	Linear	1	42,38	445
nu-SVC	Polynomial	0,1	42,38	445
nu-SVC	Polynomial	0,5	42,38	445
nu-SVC	Polynomial	1	42,38	445
nu-SVC	RBF	0,1	44,57	468
nu-SVC	RBF	0,5	44,57	468
nu-SVC	RBF	1	44,57	468
nu-SVC	Sigmoid	0,1	40,09	421
nu-SVC	Sigmoid	0,5	40,09	421
nu-SVC	Sigmoid	1	40,09	421

Base 30 s (5 gêneros)				
Parâmetros		Acertos (%)	ICC	
SVM	Kernel	C		
	Default		56,00	420
C-SVC	Linear	0,1	56,13	421
C-SVC	Linear	0,5	59,07	443
<b>C-SVC</b>	<b>Linear</b>	<b>1</b>	<b>60,13</b>	<b>451</b>
C-SVC	Polynomial	0,1	36,27	272
C-SVC	Polynomial	0,5	36,27	272
C-SVC	Polynomial	1	36,27	272
C-SVC	RBF	0,1	52,00	390
C-SVC	RBF	0,5	54,80	411
C-SVC	RBF	1	56,00	420
C-SVC	Sigmoid	0,1	50,93	382
C-SVC	Sigmoid	0,5	52,67	395
C-SVC	Sigmoid	1	55,07	413

Base 30 s (5 gêneros)				
Parâmetros		Acertos (%)	ICC	
SVM	Kernel	C		
nu-SVC	Linear	0,1	56,67	425
nu-SVC	Linear	0,5	56,67	425
nu-SVC	Linear	1	56,67	425
nu-SVC	Polynomial	0,1	58,00	435
nu-SVC	Polynomial	0,5	58,00	435
nu-SVC	Polynomial	1	58,00	435
nu-SVC	RBF	0,1	59,73	448
nu-SVC	RBF	0,5	59,73	448
nu-SVC	RBF	1	59,73	448
<b>nu-SVC</b>	<b>Sigmoid</b>	<b>0,1</b>	<b>56,67</b>	<b>425</b>
nu-SVC	Sigmoid	0,5	56,67	425
nu-SVC	Sigmoid	1	56,67	425

### Base 30 s (MPB x SAMBA)

#### Parâmetros

<b>C-SVC (Linear- 1)</b>	<b>55,33</b>	<b>166</b>
--------------------------	--------------	------------

# APÊNDICE L- RESULTADOS PARA A BASE COM DURAÇÃO DE 30 s (*BAGGING*)

Base 30 s (7 gêneros)		
Parâmetros	Acertos (%)	ICC
RF (I (800))	48,48	509
<b>SimpleEstimator e TAN</b>	<b>50,86</b>	<b>534</b>
K (15)	39,33	413
nu-SVC (RBF-1)	44,76	470

Base 30 s (5 gêneros)		
Parâmetros	Acertos (%)	ICC
RF (I (600))	61,87	464
<b>SimpleEstimator e TAN</b>	<b>62,40</b>	<b>468</b>
K (13)	51,47	386
nu-SVC (RBF-0,1)	59,60	447

Base 30 s (MPB x SAMBA)		
Parâmetros	Acertos (%)	ICC
RF (I (600))	58,00	174
<b>SimpleEstimator e TAN</b>	<b>61,67</b>	<b>185</b>
K (13)	53,67	161
nu-SVC (RBF-0,1)	56,00	168



# APÊNDICE M- RESULTADOS PARA A BASE COM DURAÇÃO DE 30 s (*BOOSTING*)

Base 30 s (7 gêneros)		
Parâmetros	Acertos (%)	ICC
RF (I (800))	47,81	502
<b>SimpleEstimator e TAN</b>	<b>45,43</b>	<b>477</b>
K (15)	38,48	404
nu-SVC (RBF-1)	45,24	475

Base 30 s (5 gêneros)		
Parâmetros	Acertos (%)	ICC
<b>RF (I (600))</b>	<b>62,00</b>	<b>465</b>
SimpleEstimator e TAN	59,47	446
K (13)	51,60	387
nu-SVC (RBF-0,1)	57,60	432

Base 30 s (MPB x SAMBA)		
Parâmetros	Acertos (%)	ICC
RF (I (600))	54,66	164
<b>SimpleEstimator e TAN</b>	<b>60,67</b>	<b>182</b>
K (13)	57,33	172
nu-SVC (RBF-0,1)	48,00	144

## APÊNDICE N- COMPARAÇÃO DOS RESULTADOS OBTIDOS

Base Inteira (7 gêneros)		
Parâmetros	Acertos (%)	ICC
<b>RF (I (800))</b>	<b>52,95</b>	<b>556</b>
SimpleEstimator e TAN	48,19	506
KNN (15)	39,43	414
nu-SVC (RBF-1)	44,47	467
Boosting - RF (I (800))	50,76	533
Bagging - RF (I (800))	52,10	547

Base Inteira (5 gêneros)		
Parâmetros	Acertos (%)	ICC
RF (I (600))	65,60	492
SimpleEstimator e TAN	62,67	470
KNN (9)	53,47	401
nu-SVC (Linear – 0,5)	59,07	443
Boosting - RF (I (600))	64,93	487
<b>Bagging - SimpleEstimator e TAN</b>	<b>66,53</b>	<b>499</b>

Base Inteira (MPB x SAMBA)		
Parâmetros	Acertos (%)	ICC
RF (I (600))	56,00	168
<b>SimpleEstimator e TAN</b>	<b>63,00</b>	<b>189</b>
KNN (9)	52,33	157
nu-SVC (Linear-0,5)	54,00	162
Boosting - SimpleEstimator e TAN	62,67	188
Bagging - SimpleEstimator e TAN	61,67	185

Base 30 s (7 gêneros)		
Parâmetros	Acertos (%)	ICC
RF (I (400))	49,04	515
SimpleEstimator e TAN	45,43	477
KNN (15)	38,48	404
nu-SVC (RBF-1)	44,57	468
Boosting - RF (I (800))	47,81	502
<b>Bagging - SimpleEstimator e TAN</b>	<b>50,86</b>	<b>534</b>

Base 30 s (5 gêneros)		
Parâmetros	Acertos (%)	ICC
<b>RF (I (500))</b>	<b>62,53</b>	<b>469</b>
SimpleEstimator e TAN	59,47	446
KNN (13)	51,60	387
nu-SVC (RBF- 0,1)	59,73	448
Boosting - RF (I (600))	62,00	465
Bagging - SimpleEstimator e TAN	62,40	468

Base 30 s (MPB x SAMBA)		
Parâmetros	Acertos (%)	ICC
RF (I (500))	54,67	164
SimpleEstimator e TAN	60,67	182
KNN (13)	57,33	172
nu-SVC (RBF- 0,1)	54,00	162
Boosting - SimpleEstimator e TAN	60,67	182
<b>Bagging - SimpleEstimator e TAN</b>	<b>61,67</b>	<b>185</b>